Los problemas ambientales del planeta se nos muestran cada día más cercanos, creciendo el interés social hacia su mejor conocimiento y resolución. Se busca un modelo de desarrollo más armónico, donde la Naturaleza no sólo sea fuente de recursos, sino también lugar de encuentro, donde aprendamos a conocer y a conocernos, a valorar la belleza y el valor de la vida.
La observación de nuestro planeta que realizan los satélites de teledetección permite enriquecer notablemente la información disponible sobre algunos de esos problemas ambientales: calentamiento terrestre, capa de ozono, dinámica de vegetación o cultivos, corrientes oceánicas, por citar sólo algunos ejemplos.

Este tratado pretende presentar los fundamentos de la teledetección, orientados principalmente hacia su aplicación ambiental. Se ha pretendido que la redacción tenga un enfoque didáctico, para lo que se apoya en numerosas figuras y tablas. Se recogen las principales novedades en la adquisición y procesado de imágenes satélite, como las técnicas hiperespectrales, la fusión de datos de distinta resolución, o los métodos de análisis temporal. El texto se completa con un CD-ROM donde se recogen fuentes adicionales de información, imágenes de ejemplo, así como una colección de presentaciones en formato *powerpoint*, que pueden servir como recurso para la docencia de esta materia.

Ariel Ciencia

938158
www.ariel.es
9 788434 480728

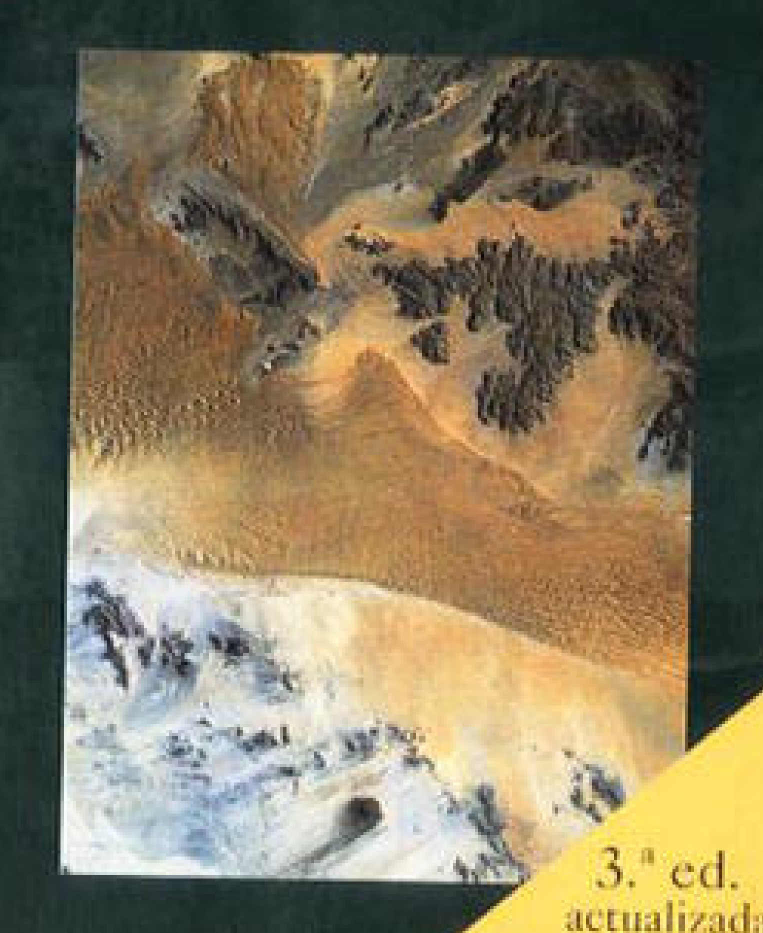
Emilio Chuvieco Salinero

Teledetección ambiental

La observación de la Tierra desde el Espacio

CONTIENE CD-ROM

Ariel Ciencia



3.ª ed. actualizada

ÍNDICE

SEGUNDA PARTE

LA INTERPRETACIÓN DE LOS DATOS

ANEXOS

PRESENTACIÓN

La observación de la Tierra desde el espacio ha experimentado en los últimos años un vertiginoso desarrollo, llegando a ser un aliado cada vez más imprescindible en el seguimiento de procesos ambientales de gran impacto para nuestro planeta. El deterioro de la capa de ozono, la detección precoz del fenómeno del niño, el avance de la desertificación o la deforestación tropical son ejemplos relevantes de las múltiples aplicaciones ambientales que brinda la teledetección. Sin embargo, en ésta como en otras nuevas tecnologías, resulta clave realizar un importante esfuerzo en la educación y formación continuada. Aprovechar el flujo de información que proporcionan los satélites de observación terrestre requiere conocer los fundamentos de la adquisición, su sentido biofísico, los criterios de interpretación más destacados, su engarce con otras fuentes de información más convencionales.

Este texto, fruto de la revisión y puesta al día de la obra *Fundamentos de Teledetección Espacial*, que publicamos en 1990 y 1996, pretende ser una modesta aportación a la docencia de esta disciplina. Aunque puede adaptarse a estudiantes y profesionales de distinta orientación, hemos intentado que tenga una clara orientación ambiental, de ahí el nuevo título de la obra. La teledetección ya forma parte de los planes de estudio de diversas disciplinas territoriales: Geografía, CC. Ambientales, Geología, Oceanografía, Ingeniería Cartográfica, Forestal o Agrícola, entre otras, pero todavía resulta necesario extender su integración con otras materias y ampliar su papel en proyectos de investigación temática. Además, el creciente empleo de las imágenes de satélite en tareas de gestión del territorio (inventarios forestales o agrícolas, actualización de límites urbanos, prevención de desastres, etc.), implican que ese esfuerzo docente debe extenderse también a cursos de actualización profesional y programas de posgrado, donde todavía el desarrollo, al menos en nuestro país, resulta bastante discreto.

Hemos mantenido el esquema general de las primeras ediciones de esta obra, ampliando aquellos aspectos que considerábamos más novedosos, como lo referente a sensores y técnicas hiperespectrales, sistemas de alta resolución espacial, técnicas de fusión de datos, de modelización de la señal y nuevos enfoques en la clasificación. Se ha extendido también el análisis de las correcciones radiométricas de las imágenes, incluyendo los efectos de los ángulos de iluminación y observación, y la detección de nubes. Asimismo, hemos ampliado el capítulo de verificación de resultados, incluyendo variables de intervalo y estudios multitemporales. En el resto de los capítulos, hemos procurado poner al día lo más sustancial, aclarando algunos epígrafes que, en opinión de nuestros alumnos (verdaderos deudores de esta obra) merecían un cambio de

enfoque. En esta reimpresión de la edición de 2002 nos hemos limitado a corregir algunas erratas de tipografía detectadas o a retocar algunos párrafos que pudieran causar confusión.

La notación que incluye el texto también respeta los criterios de las primeras ediciones. Las fórmulas se citan entre corchetes [ ] con dos números separados por un punto: el primero hace referencia al capítulo en donde se incluye y el segundo al orden dentro de ese capítulo. De forma similar se citan las figuras, entre paréntesis ( ) y precedidas de la indicación fig., también con dos números. Aquellas que aparecen con un asterisco * identifican imágenes en color y están situadas en el encarte central del libro. Por último, en ocasiones se sugiere al lector acudir a otros capítulos para recabar información adicional. Esto se hará indicando la numeración de ese capítulo entre paréntesis ( ). Al final de la obra se mantienen, aunque algo enriquecidos, los apéndices donde el lector podrá encontrar información adicional sobre esta técnica, un glosario de términos y un índice temático. En esta edición hemos incorporado también un CD-ROM con material didáctico adicional: diapositivas que pueden ser de utilidad en la docencia de esta materia, imágenes para ejercicios prácticos, páginas extraídas de Internet con fuentes adicionales de información, tutoriales, etc.

Al igual que en ediciones anteriores de esta obra, mi trabajo ha estado en todo momento apoyado por los comentarios y sugerencias de alumnos, compañeros de trabajo y colegas en la docencia o investigación de esta materia. Aunque citarlos a todos aumentaría excesivamente la obligada brevedad de un prefacio, resulta de justicia reseñar a quienes han dedicado generosamente su tiempo a revisar diversos borradores de esta obra. En mi propio departamento, estoy especialmente reconocido a las sugerencias de José Sancho Comíns, Francisco Javier Salas, Inmaculada Aguado, David Riaño y Alicia Palacios, así como a la colaboración material de Gemma Ventura y Angela de Santis. Además, he contado con el inestimable consejo de expertos de otras instituciones, como Pilar Martín y Javier Martínez Vega (CSIC), Joaquín Meliá y Vicente Caselles (Universidad de Valencia), Xavier Pons (Autónoma de Barcelona) y Javier Hervás (JRC). Finalmente, la estancia en la Universidad de California, en Berkeley, ha sido clave para actualizar el contenido del texto y algunos materiales gráficos. A Greg Biging y Peng Gong les estoy especialmente agradecido por su acogida.

Como dice un autor norteamericano, Leo Trese, «nuestra existencia será poco feliz si no tenemos la convicción de que la vida está llena de sentido. Todo lo que hacemos, consciente y voluntariamente, lo hacemos por un fin; existe una razón por la que actuamos así». Mi propósito al escribir este texto, al igual que ocurrió con la primera edición en 1990, ha sido facilitar la enseñanza de esta disciplina a estudiantes y profesionales de distintas procedencias, tanto en nuestro país como en los queridos latinoamericanos. Más allá del esfuerzo que esta tarea lleva consigo, mi mayor alegría ha sido recibir comentarios sobre su utilidad didáctica. Espero que esta nueva edición siga contribuyendo a esa tarea de formación, no sólo porque la docencia es mi principal actividad, sino porque estoy convenido de que la educación es la mejor contribución que podemos realizar al desarrollo de los pueblos.

Alcalá de Henares, febrero de 2002 / mayo de 2006

EMILIO CHUVIECO SALINERO

PRIMERA PARTE

LA OBTENCIÓN DE LA IMAGEN

CAPÍTULO 1

NOCIONES INTRODUCTORIAS

«Es grandioso el espectáculo de las fuerzas variadas de la vida que Dios infundió en los seres creados haciéndoles desarrollarse en formas cada vez más bellas y admirables.»

CHARLES DARWIN, *El origen de las especies*

1. Definición y objetivos

Volar ha sido, desde épocas muy remotas, uno de los sueños más intensamente anhelados por la Humanidad. Pese a la persistencia del intento, sólo en fechas recientes se ha dispuesto de los medios técnicos necesarios para hacer realidad este deseo. Desde ese momento, el ritmo de la innovación tecnológica ha sido vertiginoso, lo que nos ha permitido enriquecer notablemente nuestro conocimiento sobre el Planeta y sus habitantes.

Uno de los principales acicates de esta aventura aérea ha sido la búsqueda de una nueva visión de los paisajes terrestres. El afán de remontar la limitada perspectiva de la visión humana es evidente ya desde los inicios de la aeronáutica, y llega a jugar actualmente un destacado papel en la investigación espacial.

Esa observación remota de la superficie terrestre constituye el marco de estudio de la teledetección. Este vocablo es una traducción latina del término inglés *remote sensing*, ideado a principios de los sesenta para designar cualquier medio de observación remota, si bien se aplicó fundamentalmente a la fotografía aérea, principal sensor de aquel momento. En sentido amplio —y así se tratará en este libro—, la teledetección no engloba sólo los procesos que permiten obtener una imagen, sino también su posterior tratamiento, en el contexto de una determinada aplicación. En esta obra se restringe el análisis a aquellos medios de teledetección montados sobre plataformas espaciales, de ahí el adjetivo que completa el título. Quedan relegados, por tanto, la fotografía aérea, la videografía o el radar aerotransportado, si bien resultan en muchos estudios aliados imprescindibles de los sensores espaciales. Se asume que el lector está familiarizado con las técnicas de foto-interpretación, ya que han venido siendo comunes en la mayor parte de las facultades con orientación medioambiental.

Si hemos definido la teledetección espacial como aquella técnica que permite adquirir imágenes de la superficie terrestre desde sensores instalados en plataformas espa-

ciales, estamos asumiendo que entre la Tierra y el sensor existe una interacción energética, ya sea por reflexión de la energía solar o de un haz energético artificial, ya por emisión propia. A su vez, es preciso que ese haz energético recibido por el sensor sea almacenado convenientemente, bien a bordo del satélite, bien en las estaciones receptoras, de cara a que pueda interpretarse para una determinada aplicación. Como antes comentamos, ese análisis de la información recibida se incluye también —en sentido amplio— dentro del estudio de la teledetección, aunque esté más allá de los procesos de adquisición propiamente dichos. No obstante, constituye un capítulo fundamental para nuestros intereses, por cuanto esta obra se dirige más a quienes explotan la información resultante que a quienes diseñan los sensores o las plataformas que los sustentan.

En definitiva, un sistema de teledetección espacial, tal y como se concibe en la presente obra, incluye los siguientes elementos (fig. 1.1):

1. Fuente de energía, que supone el origen de la radiación electro-magnética que detecta el sensor. Puede tratarse de un foco externo a éste, en cuyo caso se habla de teledetección pasiva, o de un haz energético emitido por el sensor (teledetección activa). La fuente de energía más importante, obviamente, es el sol.

2. Cubierta terrestre, formada por distintas masas de vegetación, suelos, agua o construcciones humanas, que reciben la señal energética procedente de (1), y la reflejan o emiten de acuerdo a sus características físicas.

3. Sistema sensor, compuesto por el sensor, propiamente dicho, y la plataforma que lo alberga. Tiene como misión captar la energía procedente de las cubiertas terrestres, codificarla y grabarla o enviarla directamente al sistema de recepción.

4. Sistema de recepción-comercialización, en donde se recibe la información transmitida por la plataforma, se graba en un formato apropiado, y, tras las oportunas correcciones, se distribuye a los interesados.

5. Intérprete, que convierte esos datos en información temática de interés, ya sea visual o digitalmente, de cara a facilitar la evaluación del problema en estudio.

6. Usuario final, encargado de analizar el documento fruto de la interpretación, así como de dictaminar sobre las consecuencias que de él se deriven.

El símil de la visión humana puede ayudar a entender el significado de estos componentes. El ojo humano (3) recibe un haz energético procedente de los objetos exteriores (2) por reflejo de la luz solar (1). Esa señal se transmite al cerebro (4), que es capaz de formar una serie de imágenes sobre el mundo real que le circunda. El individuo que observa es a la vez intérprete (5) y usuario final (6) de la imagen detectada, lo que le permite tomar decisiones sobre su propio comportamiento. En otras palabras, la visión humana forma un sistema de teledetección —muy sofisticado por cierto—, puesto que nos permite caracterizar con mucho detalle los objetos que observamos.

Sin embargo, nuestra percepción visual presenta también algunas limitaciones. Por un lado, se restringe por la sensibilidad espectral de nuestras células sensoras, que sólo nos permiten apreciar un determinado tipo de energía, denominado, por esa razón, espectro visible. Otras formas energéticas, como el calor, no son observables visualmente, por lo que parece conveniente contar con unos «ojos artificiales» que amplíen nuestras propias posibilidades. Por otro lado, el campo de visión humano está limitado por nuestra propia estatura, o a la que podemos adquirir desde observatorios

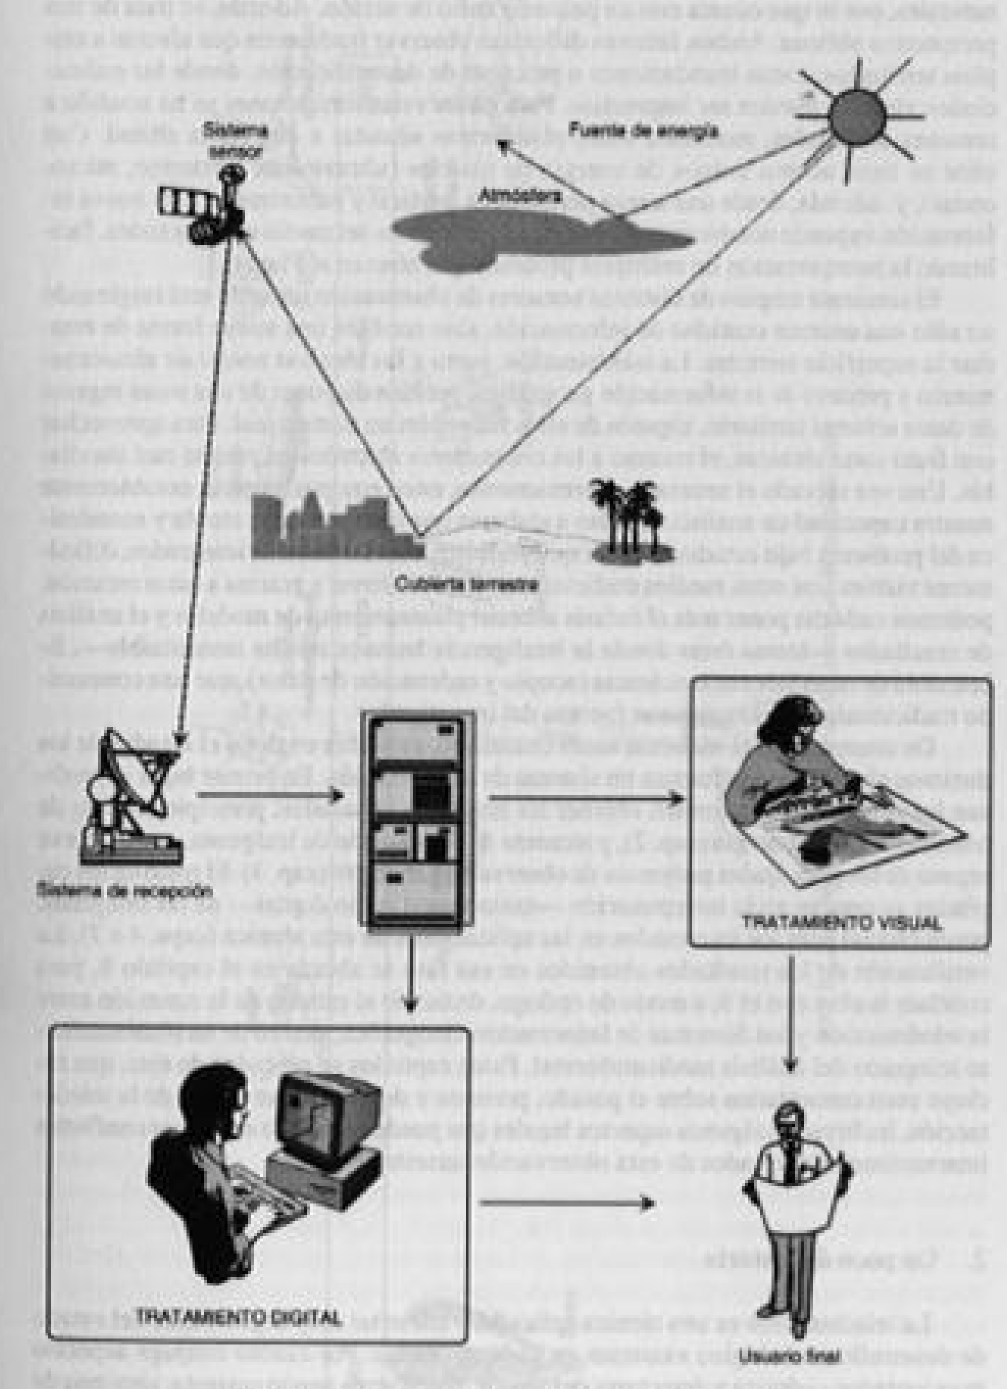


FIG. 1.1. *Componentes de un sistema de teledetección.*

naturales, por lo que cuenta con un pequeño radio de acción. Además, se trata de una perspectiva oblicua. Ambos factores dificultan observar fenómenos que afectan a amplios territorios, como inundaciones o procesos de desertificación, donde las estimaciones visuales pueden ser imprecisas. Para paliar estas limitaciones se ha acudido a sensores artificiales, montados sobre plataformas situadas a una cierta altitud. Con ellos se tiene acceso a tipos de energía no visibles (ultravioleta, infrarrojo, microondas), y, además, desde una nueva perspectiva, vertical y panorámica. Esta nueva información expande notablemente nuestro conocimiento del medio que nos rodea, facilitando la interpretación de múltiples procesos que afectan al Planeta.

El creciente empleo de distintos sensores de observación terrestre está originando no sólo una enorme cantidad de información, sino también una nueva forma de estudiar la superficie terrestre. La teledetección, junto a las técnicas anejas de almacenamiento y proceso de la información geográfica, permite disponer de una masa ingente de datos sobre el territorio, algunos de ellos accesibles en tiempo real. Para aprovechar con fruto estas técnicas, el recurso a los ordenadores electrónicos resulta casi inevitable. Una vez salvado el necesario entrenamiento, estos equipos amplían notablemente nuestra capacidad de análisis: ayudan a elaborar una interpretación rápida y económica del problema bajo estudio, a la vez que permiten abordar análisis integrados, difícilmente viables con otros medios tradicionales. En definitiva, y gracias a estos recursos, podemos cada día poner más el énfasis sobre el planteamiento de modelos y el análisis de resultados —tareas éstas donde la inteligencia humana resulta insustituible—, librándola de otras labores mecánicas (acopio y ordenación de datos), que han consumido tradicionalmente las mejores fuerzas del investigador.

De acuerdo con el esquema antes enunciado, esta obra engloba el estudio de los distintos elementos que forman un sistema de teledetección. En primer lugar se analizan los procesos que permiten obtener las imágenes espaciales: principios físicos de transmisión de la energía (cap. 2), y técnicas de adquisición de imágenes, con un breve repaso de los principales proyectos de observación terrestre (cap. 3). El resto de los capítulos se centran en la interpretación —tanto visual como digital— de las imágenes, punto crucial para los interesados en las aplicaciones de esta técnica (caps. 4 a 7). La verificación de los resultados obtenidos en esa fase se aborda en el capítulo 8, para concluir la obra con el 9, a modo de epílogo, dedicado al estudio de la conexión entre la teledetección y los Sistemas de Información Geográfica, dentro de un planteamiento integrado del análisis medioambiental. Estos capítulos se preceden de éste, que incluye unos comentarios sobre el pasado, presente y desarrollo previsible de la teledetección, incluyendo algunos aspectos legales que pueden ayudar a enmarcar conflictos internacionales derivados de esta observación terrestre.

2. Un poco de historia

La teledetección es una técnica aplicada, y como tal muy dependiente del estado de desarrollo tecnológico existente en cada momento. Por cuanto conjuga aspectos muy variados —óptica y detectores del sensor, plataforma que lo sustenta, sistemas de transmisión, equipos de tratamiento, etc.—, las formas de teledetección han variado ostensiblemente en las últimas décadas (fig. 1.2). El crecimiento ha sido realmente

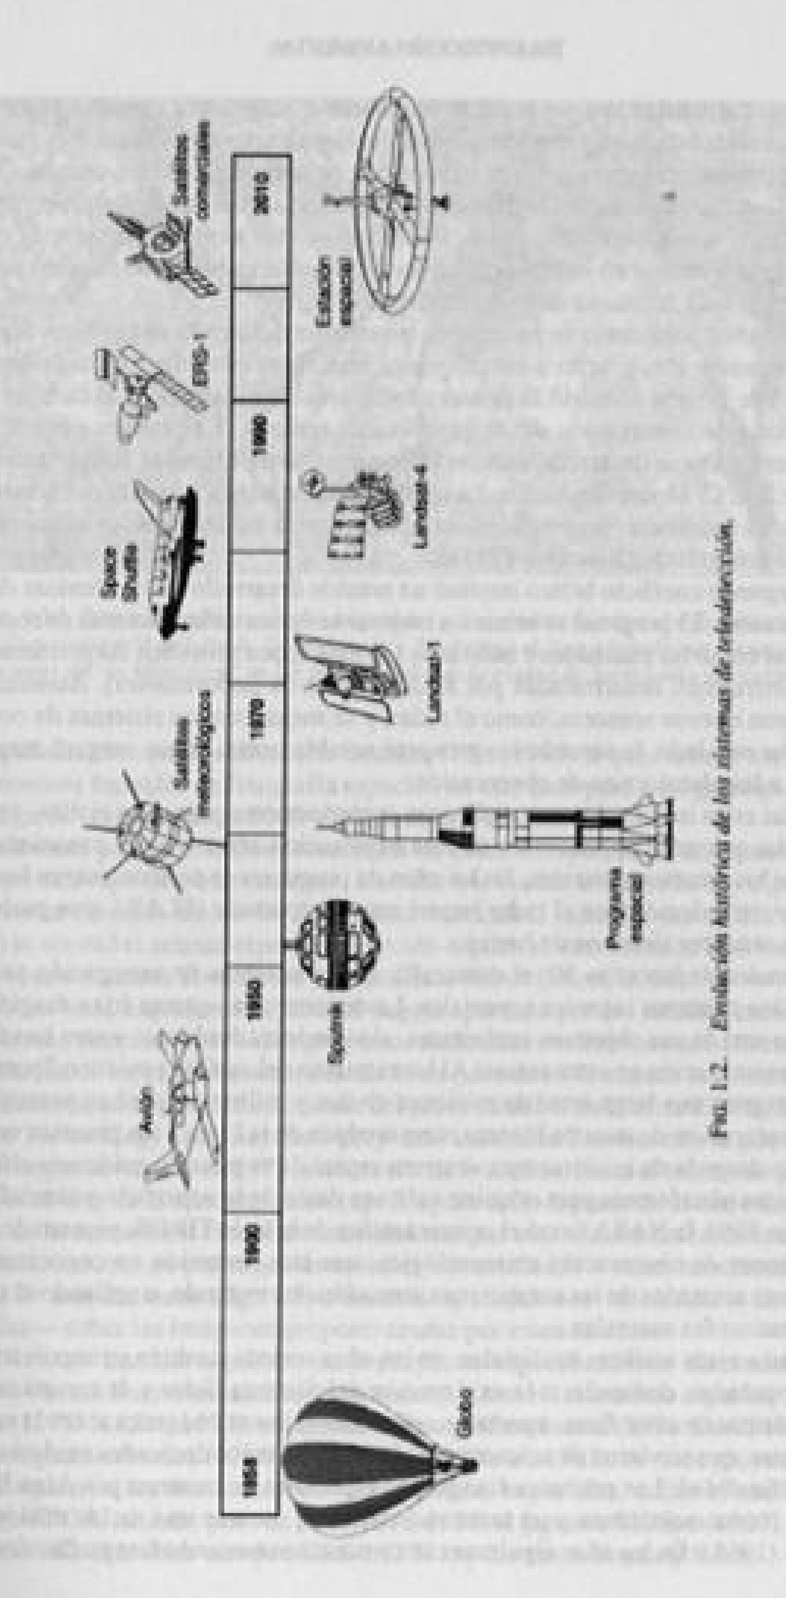


FIG. 1.2. *Evolución histórica de los sistemas de teledetección.*

vertiginoso, facilitando una progresión muy notable, tanto en la cantidad como en la variedad y calidad de la información disponible para campos científicos muy variados.

Las primeras experiencias de teledetección se remontan a 1859, cuando Gaspar Félix de Tournachon obtuvo las primeras fotografías aéreas desde un globo cautivo (Hyatt, 1988). Al año siguiente, James Wallace repitió la experiencia sobre la ciudad de Boston, poniéndose en evidencia el interés de la nueva perspectiva aérea para un conocimiento más detallado de la organización urbana.

En los años posteriores se produjo un importante desarrollo de la observación fotográfica desde avión, gracias a los progresos realizados en ópticas y emulsiones. En 1909, Wilbur Wright adquirió la primera fotografía aérea, abriendo el camino a una larga historia de observación desde plataformas remotas. La primera cámara aérea propiamente dicha se desarrolló durante la Primera Guerra Mundial, concretamente en 1915, por J. T. C. Moore-Brabazon. La importancia estratégica de este escrutinio quedó pronto en evidencia, desarrollándose notablemente las técnicas de adquisición y procesado fotográfico (Brookes, 1975).

El segundo conflicto bélico implicó un notable desarrollo de las técnicas de teledetección aérea. El progreso se orientó a mejorar la óptica de las cámaras de reconocimiento, así como las emulsiones utilizadas (de esta época proceden las primeras películas en infrarrojo, desarrolladas por *Kodak Research Laboratories*). Asimismo, se introdujeron nuevos sensores, como el radar, y se mejoraron los sistemas de comunicación. Por otro lado, la aeronáutica prosperó notablemente, lo que aseguró mayor estabilidad a las plataformas de observación.

Todas estas innovaciones se aplicaron posteriormente para usos civiles, desarrollándose las primeras aplicaciones de esta exploración aérea para el conocimiento y control de los recursos naturales. En los años de posguerra se perfeccionaron los sistemas radar, introduciéndose el radar lateral aerotransportado (SLAR), y se pusieron a punto los sensores térmicos de barrido.

A finales de los años 50, el desarrollo de los sistemas de navegación permitió concebir los primeros ingenios espaciales. La denominada «guerra fría» dirigió hacia el espacio uno de sus objetivos preferentes, alentándose, desde uno y otro bando, una intensa investigación en estos temas. Al lanzamiento del satélite soviético Sputnik, en 1957, le siguen una larga serie de misiones civiles y militares, que han permitido no sólo la exploración de nuestro Planeta, sino también de la Luna y los planetas vecinos.

Poco después de iniciarse esta «carrera espacial» se puso en evidencia el interés de usar estas plataformas para adquirir valiosos datos de la superficie y atmósfera terrestre. En 1960, la NASA lanzó el primer satélite de la serie TIROS, pionero de múltiples misiones de observación meteorológica, que han permitido un conocimiento y control más ajustados de las condiciones atmosféricas, evitando, o paliando al menos, graves catástrofes naturales.

Junto a estos satélites artificiales, en los años sesenta también se impulsaron misiones tripuladas, dedicadas a la exploración del Sistema Solar y la conquista de la Luna. Además de estos fines, aportaron asimismo valiosas imágenes sobre la superficie terrestre, que sirvieron de acicate para planear proyectos dedicados exclusivamente a esta finalidad. Las primeras fotografías espaciales se tomaron por Alan B. Shepard, de forma espontánea y un tanto rudimentaria, durante una de las misiones del Mercury (1961). En los años siguientes se continuaron tomando fotografías desde na-

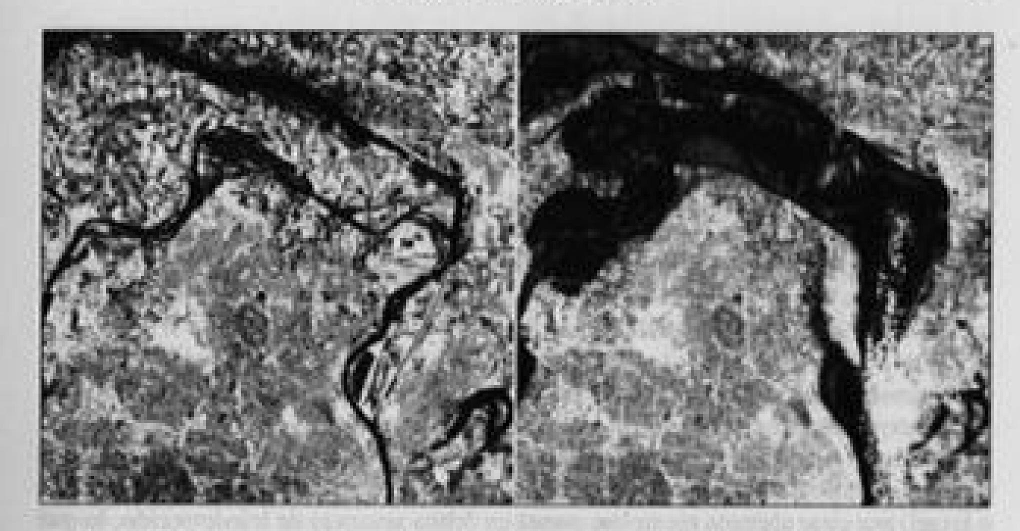


FIG. 1.3. *Imágenes multitemporales adquiridas por el satélite Landsat el 4 de julio de 1988 (izquierda) y 18 de julio de 1993 (derecha). Se observa el área afectada por las severas inundaciones del río Mississippi, en las proximidades de la ciudad de Saint Louis.* (FUENTE: EOSAT.)

ves tripuladas, aunque fue la misión Gemini-Titán (1965) la que incluyó los primeros experimentos formales de fotografía espacial, en este caso para usos geológicos y meteorológicos (experimentos S005 y S006, respectivamente).

Alentada por los brillantes resultados de estos ensayos, la NASA continuó proyectando este tipo de observaciones. Durante los vuelos del Apollo-6 y Apollo-7 se adquirieron diversas series de fotografías verticales, mientras en el del Apollo-9 (1969) se abordó el primer experimento multi-espectral, denominado S065, compuesto por cuatro cámaras Hasselblad con distintos filtros (Short, 2001).

Todas estas experiencias, junto al bagaje aportado por los satélites meteorológicos, hicieron concebir a la NASA proyectos dedicados exclusivamente a la cartografía y evaluación de los recursos naturales. El 23 de julio de 1972 supuso la culminación de esta tendencia, con el feliz lanzamiento del primer satélite de la serie ERTS *(Earth Resources Technollogy Satellite)*. Este proyecto, bautizado Landsat con la puesta en órbita del segundo satélite en 1975, resulta el más fructífero hasta el momento para aplicaciones civiles de la teledetección (cap. 3, apdo. 5.1). A partir de la serie Landsat, el interés de la comunidad científica internacional por esta técnica ha crecido exponencialmente, contándose por miles los estudios desarrollados —sobre temáticas muy diversas, de inundaciones (fig. 1.3) a incendios, erupciones volcánicas o inventarios agrícolas— sobre las imágenes proporcionadas por estos satélites.

A la serie Landsat siguieron otros proyectos específicamente diseñados para la observación medioambiental. Los más conocidos son el laboratorio espacial tripulado Skylab (1973: NASA, 1977), el satélite oceanográfico Seasat (1978: Ford, 1980), o el de investigación térmica HCMM (1978: Short y Stuart, 1982). A estos proyectos de la NASA siguieron los diseñados por otras agencias espaciales, como el satélite franco-belga SPOT, lanzado por vez primera en 1986, el japonés MOS-1 (1987), el indio IRS-1 (1988), el satélite europeo ERS-1 (1991) y los rusos Soyuz y Salut.

Paralelamente a estas experiencias civiles, la teledetección militar seguía desarrollándose al abrigo de la guerra fría, ante la creciente necesidad de obtener información sobre instalaciones y movimientos de tropas y la también creciente complejidad del espionaje aéreo (especialmente desde el grave incidente que supuso el derribo de un avión norteamericano U-2 por Rusia en 1960). En 1958 se inició el programa de satélites CORONA, lanzado con éxito en 1960, a los que siguieron una larga lista de misiones de reconocimiento militar (ARGON, LANYARD, etc.). Estas plataformas han tenido un papel clave en las relaciones entre los bloques militares (Leghorn y Herken, 2001), si bien han sido completamente opacas a la utilización civil, hasta su desclasificación en 1995 (de las imágenes adquiridas entre 1960 y 1972).

En las últimas décadas, las misiones de teledetección se han incrementado exponencialmente, como veremos más tarde (cap. 5, apdo. 3). A las agencias espaciales con mayor experiencia en observación de la Tierra se han unido otras que han aprovechado su desarrollo tecnológico y la reducción de costes en el diseño de sensores y vehículos de lanzamiento. Esto ha permitido a Canadá, Brasil, Argentina, China, Corea del Sur, o Israel, por citar algunos ejemplos, poner en órbita sensores de teledetección, lo que ha incrementado la disponibilidad de datos y permitido reducir costes de adquisición para el usuario final. Además, no podemos dejar de mencionar el creciente papel de la iniciativa privada, que ha constituido consorcios para diseñar y explotar satélites de teledetección. Estos satélites comerciales de teledetección, aunque todavía escasos, se encuentran en la vanguardia de la tecnología y permiten apuntar un amplio crecimiento de sus aplicaciones operativas. Entre ellas caben citar, junto a algunas ya consolidadas como la cartografía, gestión ambiental o localización de instalaciones, otras que afectan a sectores apenas involucrados previamente con la teledetección (tabla 1.1), como pueden ser los medios de comunicación (fig. 1*), las empresas de seguros, los consorcios turísticos, las ONGs responsables de la asistencia en situaciones de catástrofe, los grupos ambientalistas, o los comités internacionales que velan por los derechos humanos y apoyan actividades humanitarias, asistencia a refugiados, etc. (Baker, 2001; Baker *et al.*, 2001; O'Connell y Lachman, 2001).

En cuanto a las tendencias previsibles en un inmediato futuro, podemos citar la mayor disponibilidad de datos, gracias a las nuevas misiones que se están diseñando, pero también a las reducciones del coste y la mayor facilidad para transmitir esos datos a través de Internet. Ya hay algunos proveedores que facilitan imágenes utilizando servidores FTP, lo que permite disponer de ellas en un tiempo muy cercano a la adquisición. En cuanto a los sensores, parece previsible que se mejoren los distintos tipos de resolución, y especialmente la espacial y espectral, que permitirán disponer de varios satélites con resolución métrica y capacidad hiperespectral. En este sentido, conviene subrayar la importancia de los consorcios industriales privados, que estimularán nuevas aplicaciones, satisfaciendo las necesidades de usuarios específicos. La magnífica experiencia de la comunidad meteorológica, que utiliza rutinariamente imágenes de satélites en las tareas de prevención, estimulará el diseño de misiones adaptadas a determinadas aplicaciones (detección de incendios, catastro, medios de comunicación, control de embalses, etc.). Finalmente, conviene también señalar la importancia de nuevas tecnologías de teledetección, que hasta hace muy poco eran exclusivas de sensores experimentales, y ya se están montando sobre plataformas aéreas y espaciales: equipos lídar, radares interferométricos, etc., que luego tendremos ocasión de comentar.

TABLA 1.1. *Comparación entre aplicacines convencionales y nuevas de la teledetección (adaptado de Baker, 2001)*

Usuarios tradicionales	*Nuevos usuarios*
Gobiernos: — Planificadores civiles. — Fuerzas armadas. — Servicios de inteligencia. — Centros científicos. — Entidades regionales y locales.	*Medios de comunicación:* — De información general (televisiones, periódicos). — De información específica (revistas). — Editoriales.
Organizaciones internacionales: — Agencias de la ONU (refugiados, medio ambiente...). — Programas de cambio global. — Centros regionales (p. ej., UEO).	*ONGs:* — Ambientalistas. — Control de armamentos, desarme. — Ayuda humanitaria. — Derechos humanos. — Gestión de catástrofes.
Empresas: — Extracción de recursos (petróleo, gas...). — Gestión de recursos (forestales, agrícolas...). — Aerofotografía. — Diseño y lanzamiento de sensores. — Diseño y venta de *software* de tratamiento digital. — Empresas de SIG.	*Empresas:* — Redes de distribución (electricidad, agua...). — Seguros. — Agricultura de precisión. — Evaluación de impacto ambiental. — Promoción turística.
Universidades y centros de investigación: — Departamentos de Geografía, Geología, Biología, Ing. Geodésica, Agronomía, etc. — Centros de Teledetección. — Departamentos de Física, Informática, Ing. Telecomunicación.	*Universidades y centros de investigación:* — Departamentos de Arqueología, transportes. — Centros multimedia. — Departamentos de Geopolítica.
Organizaciones profesionales: — Teledetección. — Campos afines a las aplicaciones.	*Clientes finales:* — Mercado inmobiliario. — Decoración.

3. Desarrollo actual

Pese a la juventud de esta tecnología, son ya numerosos los centros de producción, enseñanza e investigación que trabajan activamente en este campo. Las tendencias presentes parecen confirmar un creciente desarrollo de su aplicación, tanto en países desarrollados como en aquellos con una situación tecnológica más deficiente. Las últimas décadas, y muy especialmente los últimos años, han implicado una disponibilidad creciente de datos provenientes de sensores muy variados, y de misiones espaciales muy diversificadas, aumentando exponencialmente las investigaciones científicas y las aplicaciones operativas de esta técnica. Basta simplemente teclear la palabra teledetección (o su equivalente inglés) en cualquier buscador de información disponible en Internet (Altavista, Copérnico...), para comprobar la ingente cantidad de información disponible sobre esta técnica: sensores, satélites, proyectos, informes, cursos,

asociaciones, etc. En una reciente estancia en la Universidad de California en Berkeley (ciertamente una de las mejores del mundo) tuvimos ocasión de comprobar que la biblioteca disponía de 2.659 libros e informes sobre este tema, reflejo de que se trata de una técnica bastante consolidada en la comunidad académica.

Siguiendo a Curran (1985), podemos distinguir cuatro estadios en el desarrollo de cualquier disciplina. El primero vendría dado por un período preliminar de crecimiento, con una tradición investigadora escasa, y pocas o ninguna asociación dedicada a su estudio. El segundo correspondería a un período de crecimiento exponencial, doblándose el número de publicaciones a intervalos regulares, a la vez que se establecen unidades de investigación. En el tercer nivel, el índice de crecimiento comenzaría a declinar, aumentando el nivel de especialización y controversia, aunque no existan importantes aumentos en el volumen de especialistas. Finalmente, el último período se caracterizaría por un nivel de crecimiento cercano a cero: las unidades de especialización y sociedades profesionales se consolidan y la ciencia adquiere madurez.

Dentro de este esquema, la teledetección ocupa estadios muy diversos según los países. Ya en 1985, Curran indicaba que «la mayor parte de los países en desarrollo se encuentran en el primer nivel, la mayor parte de los países europeos en el segundo, y Estados Unidos comienza a entrar en el tercer estadio» (Curran, 1985, p. 7). Actualmente podemos estimar que EE. UU. y algunos países occidentales se acercan a la tercera etapa, mientras buena parte de los países en desarrollo se encuentren entre el primero y segundo estadio, aunque algunos intermedios ya han alcanzado el tercer escalón. Para Jensen (2000), que no distingue entre distintos países aunque implícitamente hace referencia a la situación de EE. UU., la teledetección se encuentra en la segunda etapa de desarrollo, ya que se mantiene el crecimiento exponencial en lo que se refiere a publicaciones, centros de investigación y avances tecnológicos, aunque se aproxima a la tercera en lo que se refiere al nivel de controversia teórica.

Un breve repaso por áreas geográficas nos servirá para tener una evaluación más precisa de las diversidades geográficas en la implantación de esta técnica. En los apéndices y el CD-ROM se incorpora información adicional sobre las instituciones que se citan a lo largo de los siguientes párrafos.

Como parece lógico por el papel pionero que EE. UU. ha tenido en los satélites de teledetección, en ese país el desarrollo de esta técnica es especialmente relevante, tanto académica como comercialmente. De acuerdo a un informe sobre la privatización del proyecto Landsat remitido al Congreso de Estados Unidos (O.T.A., 1984), ya a principios de los ochenta existían en ese país más de 50 organizaciones comerciales dedicadas al empleo de la teledetección espacial. En más de 18 estados se utilizaban datos Landsat para la construcción de sus sistemas de información territorial, y sólo en 2 no se habían constatado estudios realizados a partir de imágenes de este satélite. Con datos de 1977, este mismo informe registraba 590 profesores e investigadores universitarios trabajando en teledetección. En ese mismo año se ofrecían 137 cursos sobre esta técnica en universidades americanas, con un total de 2.906 inscritos. A finales de los ochenta, se contabilizaban 549 cursos ofrecidos en teledetección por más de 300 departamentos de 125 universidades (Kiefer, 1988).[1]

1. Jensen y Dahlberg (1983) cifraban en 691 los cursos de teledetección ofrecidos en universidades americanas, incluyendo los relativos a fotografía aérea, más del 80 % de los cuales se dictaban en uni-

Respecto a actividades profesionales, la mayor parte de las iniciativas se canalizan a través de la *American Society for Photogrammetry and Remote Sensing*, que cuenta con unos 7.000 afiliados y casi doscientas empresas y socios institucionales. Entre los socios, un 30 % pertenecen al sector privado, lo que da idea de la actividad comercial en este campo. Esta asociación publica mensualmente la revista *Photogrammetric Engineering and Remote Sensing*, una de las más prestigiosas de teledetección. Otras instituciones de gran actividad son los diversos centros NASA (especialmente *Goddard*, en Maryland, y *Ames Research Center* y *Jet Propulsion Laboratory*, en California). Entre los departamentos universitarios, cuenta con gran tradición el *Laboratory for Applications of Remote Sensing* (LARS) de la Universidad de Purdue (Indiana), el *Institute for Environmental Studies* de la Universidad de Wisconsin-Madison, y la *Remote Sensing Unit* de la Universidad de California en Santa Barbara, por citar sólo los más significativos. De gran importancia también es el *U.S. Geological Survey*, que se encarga, a través del *EROS Data Center*, de la distribución de una amplia colección de imágenes tomadas por distintos sensores. La NASA *(National Aeronautics and Space Administration)* y NOAA *(National Oceanic and Atmospheric Administration)* mantienen la distribución de sus programas propios (actualmente el Terra y las series meteorológicas NOAA y GOES, entre otras).

En cuanto al mercado de productos de teledetección, y de acuerdo a un informe de la oficina de asesoramiento tecnológico del Congreso, se estimaba que el mercado de teledetección podría situarse entre 150 y 200 millones de dólares anuales para los datos brutos, y unos 500 millones para los servicios de valor añadido, con un incremento previsto de entre el 15 y el 20 % anual (O.T.A, 1994). El desarrollo de ese mercado se ha visto muy ligado al creciente recurso a la información espacial, facilitada por el propio desarrollo de los Sistemas de Información Geográfica (SIG) y la generosa política de acceso gratuito a los datos. Para el caso concreto de los datos de teledetección, la comercialización privada del programa Landsat supuso un serio revés a las aplicaciones civiles, ante el elevado aumento de los costes. La situación ha cambiado con la nueva plataforma (Landsat-7), que ofrece una política de distribución mucho más ventajosa (cap. 3, apdo. 5.1).

El mercado de la teledetección espacial, no obstante, se prevé que dé un fuerte impulso con el afianzamiento de los satélites comerciales, que están explorando vías de negocio antes inaccesibles a la observación espacial. No obstante, aunque el mercado parece bastante prometedor, todavía están por cumplirse las expectativas que han llevado a grandes inversiones en el desarrollo y lanzamiento de estos satélites comerciales (O'Connell y Lachman, 2001). Actualmente están disponibles el Ikonos, gestionado por *Space Imaging* que se lanzó en 1999; EROS A1, propiedad de *ImageSat International*, lanzado en 2000, y Quickbird (fig. 1.4), lanzado en octubre de 2001 por la empresa *Digital Globe*. Si se mantienen las tendencias, no cabe duda que estos satélites comerciales reemplazarán actividades realizadas hasta ahora mediante sensores aeroportados, especialmente a partir de fotografía aérea convencional, si bien esto requiere una sensible mejora en los precios y en la regularidad de las adquisiciones (cobertura de nubes, mayor disponibilidad de plataformas, etc.). Además de estas empre-

versidades públicas. Los departamentos más activos, en esta docencia, eran los de Geografía (36 %), Geología (14,8 %) e Ingeniería Civil (8 %).



FIG. 1.4. *Imagen pancromática del Quickbird sobre la ciudad de Lima correspondiente al 17 de diciembre de 2001, pocas semanas después del lanzamiento.* (Cortesía: DigitalGlobe.)

sas, otras 10 han solicitado al gobierno norteamericano autorización para desarrollar constelaciones comerciales de teledetección (O'Connell y Hilgenberg, 2001, p. 147).

En Canadá la situación también es muy favorable, contando con una institución nacional, el *Canada Center for Remote Sensing*, que cuenta con diversos centros regionales y coordina la actividad docente e investigadora en teledetección. También en este país ejerce su actividad una sociedad profesional, la *Canadian Remote Sensing Society*, dedicada a la organización de congresos periódicos y la publicación de una interesante revista, *Canadian Journal of Remote Sensing*. El lanzamiento del satélite Radarsat ha contribuido notablemente al afianzamiento industrial de esta técnica y a la apertura de nuevas aplicaciones.

En el contexto europeo, el Reino Unido y Francia han sido los países que se han involucrado más en la investigación aplicada en esta técnica. En cuanto al primero, ya a inicios de los ochenta, podían citarse hasta cincuenta instituciones que trabajaban activamente sobre ella (Bullard y Dixon-Gough, 1985), con una producción bibliográfica muy significativa: varios manuales universitarios, diversas publicaciones científicas (*International Journal of Remote Sensing*, *NRSC Newsletter*), y una sociedad, la *Remote Sensing Society*, muy activa en tareas de enseñanza y difusión. Esta asociación organiza anualmente, desde 1974, un congreso en distintas universidades inglesas. En lo que a diseño de satélites se refiere, conviene citar la actividad de la empresa *Surrey Satellite Technology Ltd.*, dedicada

a la fabricación de micro-satélites, con ambiciosos planes para instalar en órbitas muy frecuentes equipos de características similares al Landsat-TM.

Las autoridades francesas han realizado un gran esfuerzo en este campo, que llevó al lanzamiento del primer satélite SPOT, en 1986, continuado por otros tres satélites de la misma serie en 1990, 1993 y 1998 (cap. 3, apdo. 5.2). El proyecto fue desarrollado por el *Centre National d'Études Spatiales* (CNES), con una pequeña colaboración de la *Swedish Space Corporation*. En el terreno de las aplicaciones, el *Groupement pour le Développement de la Télédétection Aérospatiale* (GDTA), con sede en Toulousse, ha realizado numerosos cursos de entrenamiento y ciclos de formación, coordinando a distintas instituciones gubernamentales con interés en teledetección.

Otros países europeos han mostrado gran interés en la aplicación de esta técnica para un mejor conocimiento de sus problemas medio ambientales. En los Países Bajos, la actividad docente e investigadora del *Institute for Aerospace Survey and Earth Sciences* (ITC), con sede en Enschede, ha sido muy destacada, tanto en el campo de la docencia como de la investigación *(ITC Journal)*. En Alemania, Bélgica, Italia y los países escandinavos existen numerosos centros dedicados a este tipo de investigaciones. Aunque en los países del Este europeo, la situación todavía es precaria, se están dando pasos hacia una mayor presencia de esta técnica, especialmente en los programas agrícolas y medio ambientales.

La Unión Europea (UE), como conjunto, pretende impulsar las aplicaciones de la teledetección mediante una mayor colaboración con la Agencia Espacial Europea (ESA), que ya ha lanzado varios satélites Meteosat y tres de recursos naturales (ERS-1 y ERS-2, en 1991 y 1995, respectivamente), y recientemente el Envisat. La colaboración entre la UE y la ESA se traduce en un mayor esfuerzo por utilizar las imágenes de satélite en diversas direcciones generales de la Comisión. Las más activas hasta el momento han sido las dedicadas a medio ambiente y agricultura. La primera ha promovido la realización del programa *CORINE* para obtener diversas variables de interés ambiental en el conjunto de los países miembros. De entre ellos, el dedicado a la cobertura del suelo *(CORINE-Land Cover)* se ha desarrollado casi íntegramente a partir de imágenes de satélite, cubriendo no sólo la UE, sino también los países del este de Europa y norte de África. En cuanto a la Dirección General de Agricultura, los programas más consolidados son el inventario de cultivos y la predicción de cosechas. Además, se están realizando trabajos de inventario forestal y de pastizales, así como estudios regionales sobre áreas menos favorecidas. La mayor parte de estas iniciativas parten del *Space Applications Institute* (SAI, muy recientemente fundido con un Instituto de Investigación Ambiental en el seno del centro común de investigación de la Unión Europea en Ispra). Este centro ha desarrollado investigación de base y distintas aplicaciones de la teledetección, proporcionando servicios a varias Direcciones Generales de la Comisión. En cuanto a sociedades profesionales, en el ámbito europeo conviene citar la actividad de la Asociación Europea de Laboratorios de Teledetección (*European Association of Remote Sensing Laboratories*, EARSeL), que cuenta con 300 miembros (todos ellos departamentos universitarios o centros de investigación). Organiza congresos anuales y talleres técnicos, publica un boletín de noticias *(EARSeL Newsletter)* y una revista científica basada en los artículos presentados a los distintos talleres *(EARSeL Advances in Remote Sensing)*.

El volumen de negocio del mercado europeo de la teledetección se cifró, en un es-

tudio del SAI realizado en 1995, en unos 173 millones de euros, afectando a unas 350 organizaciones, con 9.500 empleados (en el estudio no se incluían las industrias dedicadas al desarrollo de los sensores o de las estaciones receptoras). En la mayor parte de los estados las entidades de la Administración resultaban los principales clientes de esta técnica (un 65 %), frente a un 29 % del sector privado y un 6 % de entidades científicas. Las aplicaciones más demandadas eran la cartografía y planeamiento (38 %), agricultura (25 %), sector forestal (13 %) y militar (11 %).

Por no ampliar excesivamente esta relación, podemos concluir citando otros países en donde la teledetección espacial resulta una técnica de notable implantación. Este es el caso de Japón, China, Brasil y la India, empeñados en el desarrollo de proyectos espaciales propios, así como de Rusia, con una larga trayectoria en esta disciplina, aunque poco conocida para los países occidentales. Las principales organizaciones son la *National Remote Sensing Agency*, localizada en Hyderabad (India); el *Remote Sensing Technology Center* (RESTEC), situado en Tokio, y el *Instituto Nacional de Pesquisas Espaciais* (INPE), emplazado en São Jose dos Campos (Brasil).

En el ámbito iberoamericano, además del INPE brasileño, también conviene citar la actividad de la CONAE argentina, que ha lanzado recientemente (noviembre de 2000) su primer satélite de observación de la Tierra. En cuanto a centros universitarios o profesionales comprometidos con esta técnica, cuentan con especial tradición la Universidad Autónoma y el INEGI de México, el Instituto de Geografía cubano, el Centro de Procesamiento Digital de Imágenes en Venezuela, el Instituto Agustín Codazzi en Colombia, la Universidad Católica en Santiago de Chile, el CLIRSEN ecuatoriano y la Universidad de Luján y el INTA argentinos. La Sociedad de Expertos Latinoamericanos en Percepción Remota (SELPER) cuenta actualmente con unos 1.000 miembros organizados en capítulos nacionales, celebra bienalmente un congreso internacional y publica un boletín con noticias y artículos académicos.

Tras repasar el contexto internacional, resulta conveniente detenernos sobre el estado de la teledetección en nuestro país. En ésta, como en otras tecnologías de punta, el desarrollo es desgraciadamente escaso y lento, pese a que algunos de nuestros investigadores realizaran estudios pioneros en esta línea, ya a mediados de los años setenta (Núñez, 1976). A lo largo de los últimos años se evidencia un creciente interés en la comunidad científica, pero aún no se ha consolidado como una técnica suficientemente difundida. Aunque ha crecido el número y la actividad de los grupos interesados en esta técnica, no se observa todavía un cuerpo científico consolidado, y aún resulta una herramienta con poca actividad comercial, muy dependiente de las administraciones locales. Ha ganado en los últimos años en presencia en los planes de estudio universitarios, pero todavía sigue siendo escasa la oferta de programas de especialización. La actividad académica sigue de alguna manera girando en torno a la Asociación Española de Teledetección (AET), creada en 1989 tras cuatro años de actividades como grupo de trabajo. Entre sus logros cuenta la organización de ocho congresos nacionales (Barcelona, Valencia, Madrid, Sevilla, Las Palmas, Valladolid, Santiago, Albacete y Lérida), y la publicación de unas monografías especializadas *(¿Quién es quién?)* y una revista científica (la *Revista de Teledetección*) de periodicidad semestral. Lamentablemente, aún el número de afiliados es escaso (unos 200). Otra asociación interesada en esta técnica es la Sociedad Española de Cartografía, Fotogrametría y Teledetección, organizadora de cursos y seminarios esporádicos sobre estas técnicas.

Tal vez una de las principales rémoras para impulsar el desarrollo de la teledetección en España sea la inexistencia de un centro nacional de referencia, similar al NRSC inglés, al ITC holandés o al GDTA francés, que coordine los esfuerzos individuales y ponga en contacto a expertos, empresas y usuarios finales del producto. Los centros más destacados, sin pretender ser exhaustivo, son los dedicados a la producción cartográfica (Instituto Geográfico Nacional, *Institut Cartogràfic de Catalunya*, Agencia de Medio ambiente de Andalucía), a la investigación (Instituto Nacional de Técnica Aeroespacial, Instituto Nacional de Investigaciones Agrarias, Instituto Tecnológico y Geominero, Instituto de Economía y Geografía, CREAF, Instituto de Geología Jaume Almera, Instituto de Desarrollo Regional de Albacete), o a la docencia universitaria (universidades de Alcalá, Granada, Lérida, las Palmas, Santiago, Valencia y Valladolid). Existe un pequeño número de empresas dedicadas exclusivamente a esta temática (Ibersat, Aurensa,...) y otras que cuentan con departamentos de teledetección (Tragsatec, Indra, Dharma, Insa, Tecnoma). Tal vez el proyecto más ambicioso liderado por nuestro país sea la puesta en órbita de un sistema de detección de incendios, el programa Fuego, que coordina la empresa Insa, con fondos de la Agencia Espacial y la Comisión Europea.

4. Aspectos legales de la teledetección

La teledetección, como ya hemos indicado, supone la observación exterior de la superficie terrestre. El satélite, como es obvio, no ajusta su órbita a las fronteras nacionales, sino que adquiere imágenes de todo el globo. Esta adquisición de datos sobre un territorio soberano puede implicar una violación de su espacio aéreo, además de poner en evidencia información estratégica de un país que podría ser utilizada abusivamente por otro.

Por esta razones, ya desde el inicio de la teledetección se puso de manifiesto la necesidad de regular jurídicamente esas actividades. Las primeras discusiones jurídicas se produjeron a fines de los años cincuenta a propósito de los primeros satélites espía. En 1955, el presidente Eisenhower propuso en una conferencia internacional en Ginebra una política de cielos abiertos *(Open Skies proposal)*, que permitiera la observación mutua libre entre las dos potencias, con objeto de que cada una pudiera contar con información real sobre los recursos militares de la otra, reduciendo así las tensiones y la carrera armamentística. Estos vuelos de reconocimiento militar permitirían tender a una mayor confianza mutua entre EE. UU. y la Unión Soviética, relajando las tensiones (Leghorn y Herken, 2001). La propuesta no fue aceptada por el lado soviético, lo que dio lugar a un acelerado desarrollo de los sistemas espaciales de observación militar, no detectables por los métodos convencionales de protección del espacio aéreo. A partir de ahí, se inició una etapa de aceptación legal tácita de la observación espacial, ya que ambas potencias eran conscientes de que el adversario contaba con los medios para observar su territorio, sin reclamar jurídicamente el fin de esa observación. La situación jurídica de la observación militar se reguló finalmente en 1992, con el tratado de Cielos abiertos *(Open Skies Treaty)*, firmado por EE. UU., Canadá y otros estados de la OTAN, por un lado, y varios países del pacto de Varsovia, por otro, incluyendo Rusia, Ucrania y Belarus. El acuerdo permite sobrevolar el territorio de otro es-

tado utilizando sensores específicamente aprobados por el tratado (se van negociando entre las partes), con limitaciones de resolución espacial que varían con la tecnología empleada (Heric *et al.*, 1996). La caída del muro de Berlín en 1989 evidentemente ha creado un nuevo ambiente para este tipo de actividades, que pueden ser de gran interés en la prevención de riesgos militares.

En cuanto a la teledetección civil, está regulada por el Comité de Naciones Unidas para el Uso Pacífico del Espacio Exterior, que ha intentado desarrollar unos principios legales que salven las tensiones entre estados observados y observadores. El inicio de este proceso se encuentra en el tratado sobre las actividades de exploración del espacio, firmado en 1967. Allí se señalaba que «... el espacio exterior, incluso la Luna y otros cuerpos celestes, no podrá ser objeto de apropiación internacional por reivindicación de soberanía, uso u ocupación, ni mediante ningún otro medio» (*Treaty on principles goberning the activities of States in the exploration and use of outer space, including the Moon and celestial bodies*, art. II).

Este acuerdo constituye el eje sobre el que se ha venido apoyando el derecho espacial en los últimos años. Sus principales definiciones consagran un doble principio: libertad de exploración y uso del espacio exterior, y empleo en provecho común, sin posibilidad de apropiación por ningún estado. En definitiva, se define el espacio exterior como un patrimonio común de la Humanidad, no sujeto a intereses nacionales.

En el congreso UNISPACE'82, celebrado en Viena, se expresó el deseo de algunos países en desarrollo por controlar la distribución de las imágenes obtenidas sobre su territorio. Además, se convino en facilitar el acceso inmediato y no restrictivo a la información detectada sobre el territorio perteneciente a cada estado, así como en solicitar la previa autorización de éste para difundir dicha información a terceros países. Estos principios se plasmaron en la resolución 41/65 de la ONU (diciembre de 1986), que también subraya el interés de esta técnica para promover la protección del medio ambiente y la mitigación de catástrofes naturales. Las grandes directrices de esta legislación pueden resumirse en los siguientes puntos (Tapia, 1989):

1. La teledetección se realizará en provecho e interés de todos los países, de acuerdo con el derecho internacional.
2. Se respetará el principio de soberanía plena y permanente de los Estados sobre su propia riqueza y recursos naturales, sin perjudicar los legítimos derechos e intereses del Estado observado.
3. Se promoverá la cooperación internacional sobre recepción, interpretación y archivo de datos, prestándose asistencia técnica.
4. Deberán los Estados informar al Secretario General de las Naciones Unidas de los programas de teledetección que se propongan desarrollar, así como a los Estados interesados que lo soliciten.
5. Se informará a los Estados afectados para prevenir fenómenos perjudiciales para su medio ambiente, y contarán con acceso sin discriminación, y a un coste razonable, de los datos obtenidos sobre su territorio.

Estas líneas parecen marcar la evolución reciente del derecho espacial en lo que afecta a actividades de teledetección. La amplitud de estas actividades a otros países más allá de Estados Unidos y la Unión Soviética (caso de Japón, Canadá, India o Brasil), y el

creciente papel de los consorcios comerciales tiende a liberalizar aún más las disposiciones adquiridas, si bien no resultan todavía muy eficientes los mecanismos de transferencia tecnológica hacia terceros países, casi siempre los más necesitados de una información tan valiosa sobre sus propios recursos naturales. De hecho, en la Tercera Conferencia de la ONU sobre los usos pacíficos del espacio exterior (UNISPACE III) celebrada en Viena en 1999 se volvió a subrayar la preocupación de algunos gobiernos sobre la información que facilitan los satélites civiles sobre su territorio (singularmente India e Israel), si bien la principal preocupación de los países en desarrollo era conseguir reducir los costes de las imágenes, en lugar de aumentar los controles sobre su disponibilidad (Florini y Dehqanzada, 2001).

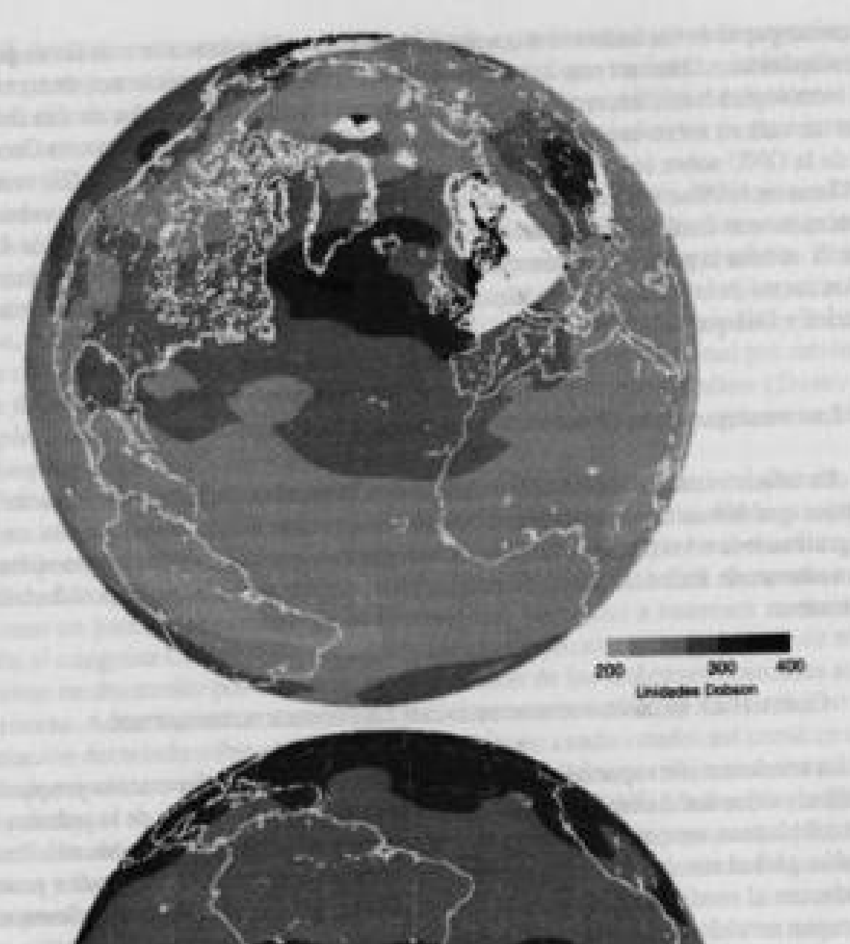
5. Las ventajas de la observación espacial

La teledetección desde satélite cuenta con numerosas aplicaciones, gracias a las ventajas que ofrece frente a otros medios de observación más convencionales, como la fotografía aérea o los trabajos de campo, aunque más que sustituirlos los complementa adecuadamente. Entre las ventajas de esta observación espacial podemos destacar las siguientes:

5.1. Cobertura global y exhaustiva de la superficie terrestre

La teledetección espacial es una de las pocas fuentes de información propiamente globales, ya que los sistemas orbitales permiten tomar información de la práctica totalidad del planeta, en condiciones comparables (mismo sensor, similar altura). Esta dimensión global resulta de enorme trascendencia para entender los grandes procesos que afectan al medio ambiente de la Tierra (Foody y Curran, 1994). Fenómenos que preocupan notablemente a la comunidad científica, y aun al hombre de la calle, como el deterioro de la capa de ozono (fig. 1.5), el calentamiento de la Tierra o los procesos de desertización, sólo pueden ser entendidos bajo una consideración global —el planeta en su conjunto—, para lo que necesitamos un sistema de información que abarque grandes espacios. Es bien conocida la dificultad para establecer bases de datos globales, ya que resulta preciso integrar información proveniente de fuentes nacionales muy diversas, que frecuentemente están compiladas con criterios (desagregación, escalas, etc.) casi incompatibles (Chuvieco, 1992; Unninayar, 1988). Además, en muchas ocasiones estos datos de partida se refieren a localizaciones puntuales (estaciones meteorológicas o de aforo), por lo que es preciso aplicar posteriormente algoritmos de interpolación para obtener una imagen completa del territorio.

La teledetección espacial nos ofrece, por el contrario, una fuente homogénea (el mismo sensor y plataforma para todos los países) y exhaustiva (cubre todo el territorio) de datos para todo el planeta, lo que permite su fácil inclusión en estudios globales. La iniciativa denominada *Data and Information Systems* (DIS), perteneciente al programa internacional para el estudio de la geosfera y la biosfera (IGBP), ya ha desarrollado algunas bases de datos globales a partir de imágenes de satélite, como el mapa mundial de la cobertura del suelo (*IGBP-Land Cover*: Brown *et al.*, 1993; Townshend *et al.*, 1991).



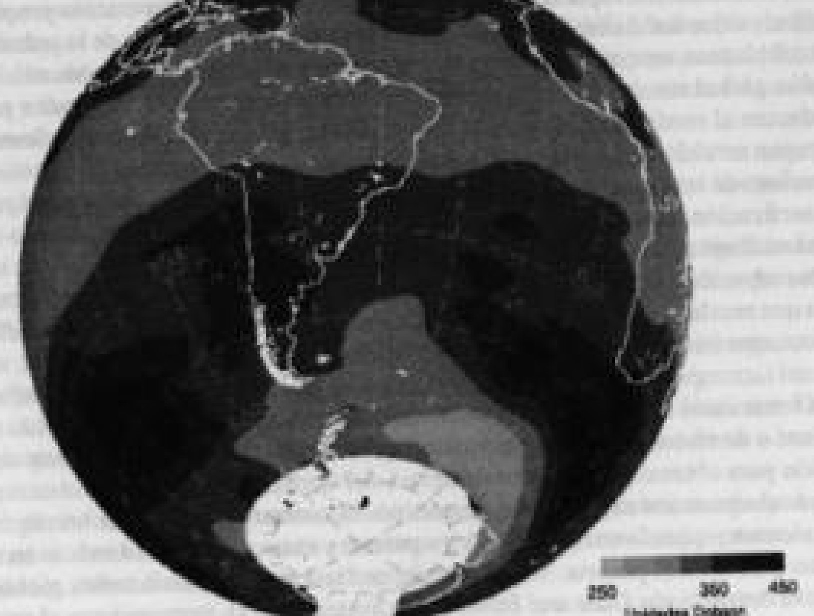


FIG. 1.5. *Estimación del espesor de la capa de ozono a partir de la senda TOMS para el 18 de agosto de 2001.* (FUENTE: DLR.)

5.2. Perspectiva panorámica

La altura orbital del satélite le permite detectar grandes espacios, proporcionando una visión amplia de los hechos geográficos. Una fotografía aérea, escala 1:18.000, capta en una sola imagen un superficie aproximada de 16 km^2, que asciende a unos 49 km^2 en el caso de fotografías a mayor altitud (escala 1:30.000). Una imagen del sensor Landsat-TM nos permite contemplar 34.000 km^2 en una sola adquisición, llegándose hasta varios millones de kilómetros cuadrados los abarcados por una sola imagen del satélite meteorológico NOAA. Determinados fenómenos de gran radio de cobertura se pueden delimitar a partir de estas imágenes, siendo de difícil percepción para perspectivas más locales. El abombamiento de la Meseta española, por ejemplo, fue detectado a partir de las primeras imágenes Landsat que se obtuvieron de nuestro país (Alía *et al.*, 1976), corrigiendo en parte la visión tradicional que se tenía de esta unidad del relieve. Sobre imágenes de satélite resulta más asequible la detección de algunas fallas, fracturas o contactos litológicos, lo que puede guiar en la localización de algunos recursos minerales (Short y Blair, 1986).

5.3. Observación multiescala

Como veremos a lo largo de esta obra, los sistemas actuales de teledetección desde satélite ofrecen un amplio rango de cobertura espacial y nivel de detalle, desde los sensores de ámbito local (con precisiones en torno a 1 m^2 y cobertura en el rango de pocos cientos de km^2), hasta los de ámbito global (con resoluciones de 1 a 5 km^2, pero que abarcan varios millones de km^2). Puesto que las variables físicas que obtienen del suelo son equiparables entre sistemas (reflectividad, temperatura...), si consiguiéramos relacionar estas distintas escalas entre sí, y esas variables nuestro parámetro de interés (p. ej., clorofila en el agua o rendimiento del cultivo), podríamos utilizar las imágenes para extender las observaciones locales a ámbitos de estimación mucho más amplios. Por ejemplo, podríamos utilizar imágenes para extrapolar cálculos extraídos de un muestreo de temperatura o clorofila en el agua, índices de área foliar, o rendimiento del cultivo. Esta capacidad de extrapolar espacialmente las observaciones puntuales tiene gran importancia en el análisis de diversos fenómenos ambientales, ya que las relaciones entre variables pueden cambiar al modificarse la escala (Ehleringer y Field, 1993).

5.4. Información sobre regiones no visibles del espectro

Los sensores ópticos-electrónicos facilitan imágenes sobre tipos de energía que no son accesibles al ojo humano o la fotografía convencional, como es el caso del infrarrojo medio y térmico o las micro-ondas. Estas bandas del espectro proporcionan una valiosa información para estudios medio ambientales. Por ejemplo, el infrarrojo térmico nos permite estudiar la distribución espacial de las temperaturas, con mayor detalle sobre la superficie marina gracias a la homogeneidad de su composición (López, 1991). El seguimiento de corrientes marinas, la detección de surgencias o focos anómalos de calor son buenos ejemplos del interés de este tipo de información, que

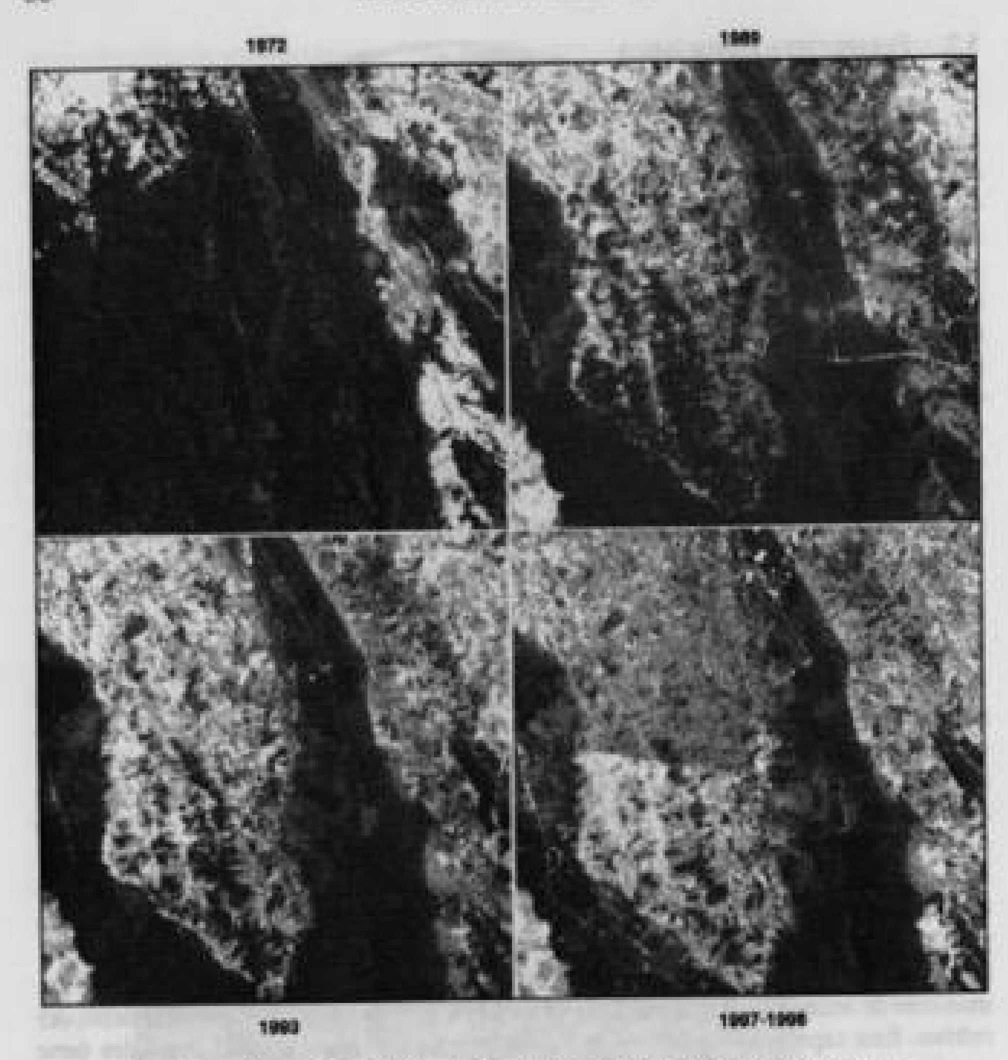


FIG. 1.6. *Avance de la deforestación en la reserva de Ticoporo (Venezuela).*
(FUENTE: Franklin, 2000.)

tienen gran interés en las aplicaciones climáticas o pesqueras (Barreto, 2000). Por otra parte, el infrarrojo medio también resulta de gran interés para la detección de focos de altas temperaturas, como es el caso de los incendios forestales, que pueden delimitarse con bastante precisión (Martín *et al.*, 1999).

5.5. COBERTURA REPETITIVA

Las características orbitales de los satélites de observación terrestre les permiten adquirir imágenes repetitivas de toda la Tierra, en condiciones comparables de observación, lo que resulta idóneo para abordar estudios multitemporales (fig. 1.6). Aunque

más tarde veremos con detalle el interés de este análisis multitemporal (cap. 7.3), pueden aquí citarse algunos ejemplos de las posibilidades ofrecidas por esta observación periódica: observación de procesos de desertificación (Tucker *et al.*, 1994), análisis de inundaciones, la predicción de la escorrentía en coberturas de nieve (Ferris y Congalton, 1989), el seguimiento de la deforestación (Nelson, 1994), y, por supuesto, la dinámica de los fenómenos meteorológicos (Conway, 1997).

5.6. TRANSMISIÓN INMEDIATA

La mayor parte de los sistemas de teledetección graban las imágenes en formato digital, lo que permite transmitirlas a las estaciones terrestres en tiempo real. En situaciones de emergencia, esta disponibilidad inmediata puede resultar vital, por lo que se considera una de las características más destacadas de la teledetección en la gestión de catástrofes (Scott, 1997). En la práctica, sólo los satélites meteorológicos ofrecen transmisión directa al usuario final, siempre que se disponga de las antenas receptoras adecuadas (fig. 1.7). El resto de los sistemas se reciben en tiempo real únicamente por la red de estaciones concertadas con la entidad propietaria del satélite, siempre que éste se encuentre en el área de grabación de alguna antena, o de lo contrario se graban a bordo para su transmisión posterior. El usuario recibe las imágenes con un cierto desfase temporal, que se dedica a la calibración de los datos y el envío. La mayor utilización de Internet en la difusión de datos puede acortar esos plazos, haciendo también posible el empleo casi inmediato de las imágenes de alta resolución espacial.

5.7. FORMATO DIGITAL

Como se comentó más arriba, el tratamiento digital de las imágenes agiliza el proceso de interpretación, permite generar modelos cuantitativos e integrar los resultados con otro tipo de información geográfica. Este enfoque integrado facilita una eva-



FIG. 1.7. *Sistema de recepción de imágenes NOAA HRPT instalado en el departamento de Geografía de la Universidad de Alcalá.*

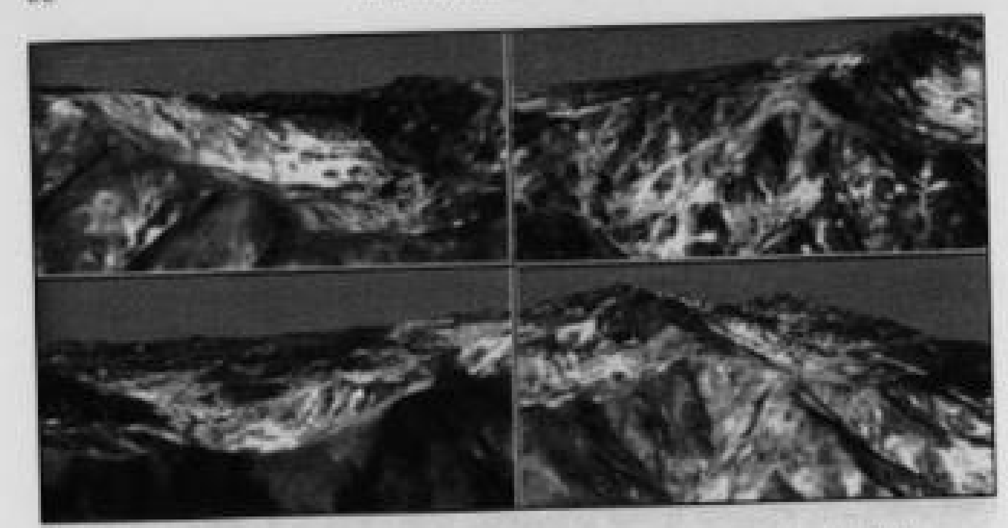


FIG. 1.8. *Diversas perspectivas tridimensionales de una imagen Landsat TM sobre la Sierra de Gredos.*

luación más real del paisaje, al considerar los principales elementos espaciales que lo conforman. Aun simplemente en el terreno de la visualización, el apoyo de los ordenadores permite observar el territorio con una precisión y plasticidad difícilmente abordable por otros medios. Éste es el caso de las perspectivas tridimensionales, que combinan una imagen de satélite con un modelo topográfico digital. El terreno puede así observarse desde distintos ángulos (fig. 1.8), de cara a diseñar trayectorias virtuales, o simular los efectos de distintas actuaciones sobre el territorio antes de que se produzcan, evitando así pérdidas irreparables.

Esta relación de las ventajas que proporciona esta técnica no implica, naturalmente, que consideremos a la teledetección espacial como una panacea para detectar cualquier problema que afecte al medio ambiente. También presenta diversas limitaciones, como son las derivadas de la resolución espacial, espectral o temporal actualmente disponibles, que pueden no ser suficientes para resolver un cierto problema. Por ejemplo, los estudios de morfología urbana hasta la llegada de los satélites comerciales de alta resolución estaban seriamente limitados, y todavía hay muchas otras aplicaciones que no son factibles con las características espectrales, temporales o espaciales de los sistemas actuales. Además, la cobertura de nubes puede reducir notablemente en algunas zonas la frecuencia temporal proporcionada por estos sistemas espaciales, restringiéndose la observación de esas áreas a la proporcionada por los sistemas de radar (cap. 3, apdo. 4.1). Finalmente, es obvio que sólo será posible distinguir fenómenos que impliquen modificar la forma en que una cubierta radia energía. Por ejemplo, no pueden discriminarse sobre una imagen de satélite variables que se desarrollan en profundidad (como el perfil de un suelo) o las que se refieren al uso del territorio, siempre que no implique un cambio de cobertura: un gran centro comercial sí implica un cambio de ocupación del suelo, pero no el uso comercial minorista, habitualmente situado en el mismo edificio —y por tanto, con la misma cubierta— que un uso residencial en altura.

Es obvio, en definitiva, que esta observación es complementaria con otras técnicas convencionales, como la fotografía aérea, y que no invalida la importancia del trabajo de campo. En otras palabras, es una técnica auxiliar más, idónea en múltiples contextos y discreta en otros, en los que su aplicación resulta sólo un ensayo experimental.

6. Fuentes bibliográficas

Como antes se indicó, la teledetección es una técnica bastante reciente, pese a lo cual la producción bibliográfica resulta ya considerable. En el panorama internacional se cuenta con numerosos congresos, revistas especializadas, manuales e informes de investigación centrados en esta tecnología. Esto explica la existencia de diversos catálogos bibliográficos, y de varias series periódicas dedicadas a la recopilación de literatura científica en este campo. Los más importantes, a este respecto, son: *Earth Resources: A Continuing Bibliography with Indexes*, publicada por NASA desde 1962, y *Geographical Abstracts, G: Remote Sensing, Photogrammetry and Cartography*, publicada por Geo Abstracts. En la misma línea se sitúa la creación de bases bibliográficas especializadas en teledetección, caso de la canadiense RESORS *(Remote Sensing Online Retrieval System)*, o la inglesa GEOBASE.

Los Congresos más destacados son los que organizan las sociedades profesionales: *International Society for Photogrammetry and Remote Sensing* (ISPRS), *American Society of Photogrammetry and Remote Sensing* (ASPRS), *International Geoscience and Remote Sensing Society* (IGARS), *Remote Sensing Society* (RSS), y *European Association of Remote Sensing Laboratories* (EARSeL). Tienen también gran prestigio la serie de congresos denominados *International Symposium on Remote Sensing of Environment*, organizados por el ERIM, los denominados *Machine Processing of Remotely Sensed Data*, que coordina el LARS, y los *Pecora Symposium*, también de la ASPRS, aunque centrados únicamente en aplicaciones medioambientales.

En el capítulo de revistas especializadas, las más destacadas son: *Canadian Journal of Remote Sensing, Geocarto International, IEEE Transactions on Geoscience and Remote Sensing, International Journal of Remote Sensing, ITC Journal, Photogrammetria, Photogrammetric Engineering and Remote Sensing, Remote Sensing of Environment, Remote Sensing Reviews* y *ISPRS Journal of Photogrammetry*. De ellas las de mayor impacto son *Remote Sensing of Environment, IEEE Transactions on Geoscience and Remote Sensing, International Journal of Remote Sensing* y *Photogrammetric Engineering and Remote Sensing*. En el ámbito de habla hispana, conviene citar la *Revista de Teledetección*, que se publica semestralmente desde 1993, el boletín de la SELPER, y la revista *Geo-focus*, de muy reciente aparición, publicada exclusivamente en versión electrónica.

En cuanto a manuales universitarios, buena muestra del grado de desarrollo alcanzado por esta técnica es la amplia gama de textos disponibles, una buena parte de ellos de reciente publicación o re-edición (Asrar, 1989; Barret y Curtis, 1999*a*; Campbell, 1996; Chen, 1985; Conway, 1997; Couzy, 1981; Cracknell y Hayes, 1991; Curran, 1985; Danson y Plummer, 1995; Drury, 1998; Elachi, 1987; Estes y Lenger, 1974; Gibson y Power, 2000*a*; Gibson y Power, 2000*b*; Harper, 1983; Harris, 1987; Holz, 1973; Hord, 1986; Howard, 1991; Jensen, 1996; Jensen, 2000; Lillesand y Kie-

fer, 2000; Lira, 1987; Lo, 1986; Mather, 1998; McCloy, 1995; Pinilla, 1995; Quattrochi y Goodchild, 1997; Rees, 1999; Richards y Xia, 1999; Robin, 1998; Ruiz, 1994; Schanda, 1976; Schowengerdt, 1997; Short, 1982; Slater, 1980; Sobrino, 2000; Swain y Davis, 1978; Szekielda, 1988; Thomas *et al.*, 1987*a*; Townshend, 1981; Verbyla, 1995; Wilkie y Finn, 1996). También se han publicado varios libros temáticos, centrándose en la aplicación de la teledetección al ámbito urbano (Au, 1993; Lulla, 1993), edafología y geología (Drury, 1998; Mulders, 1987; Rencz y Ryerson, 1999; Short y Blair, 1986), hidrología (Gower, 1994; Hall y Martinec, 1985; Robinson, 1985), climatología (Barret, 1974; Carleton, 1991; Conway, 1997), ecología del paisaje (Frohn, 1998), vegetación (Franklin, 2001; Hobbs y Mooney, 1990; Howard, 1991), o incendios forestales (Ahern *et al.*, 2001; Chuvieco, 1999*b*).

Para cuestiones didácticas resultan también de gran interés los catálogos y atlas de imágenes de satélite, que recogen abundantes ejemplos de imágenes sobre un determinado territorio o área temática de interés. Entre las obras más interesantes se cuentan: *Mission to Earth: Landsat views of the World* (NASA, 1976), *Earth Watch* (Sheffield, 1981) y *Man on Earth* (Sheffield, 1983). Las tres están basadas exclusivamente sobre imágenes Landsat, mientras *Images of Earth* (Francis y Jones, 1984) incluye algunas fotografías tomadas desde el transbordador espacial norteamericano. Con un criterio más cartográfico, destaca la obra de la casa alemana Westerman, traducida posteriormente al inglés (Smith, 1984), así como la cobertura de imágenes del Reino Unido (Bullard y Dixon-Gough, 1985), de Venezuela (Ruiz, 1992), magníficamente cuidado, de Siria (GORS, 1996), y de algunas regiones españolas (Moreira y Ojeda, 1992; Sancho, 1992; Sancho y Chuvieco, 1986), que presentan numerosos ejemplos de análisis ambiental sobre las imágenes. También con un enfoque cartográfico conviene citar la obra de varios autores del Este europeo (Sagdejew, 1982), con la novedad de que incorporaron fotografías adquiridas por plataformas soviéticas, poco accesibles hasta hace unos años en los países occidentales. Más recientemente se han publicado algunos libros más temáticos, como el dedicado a las ciudades del mundo (Au, 1993), y el que revisa los principales paisajes de Iberoamérica (Sancho y Chuvieco, 1992). Finalmente, los trabajos de la institución Smithsonian (Strain y Engle, 1993), de la Sociedad Audobon (National Audubon Society, 1995), y de la National Geographic Society (National Geographic, 1999) abarcan un amplio abanico de sensores y países. Sin duda, el más destacado en su concepción y presentación es el último, con magníficos ejemplos de imágenes procedentes de distintas misiones espaciales. En otro orden de cosas, diversas entidades cartográficas publican series de orto-imágenes de distintos sensores (principalmente Landsat-TM), a precios muy asequibles, lo que permiten extender al gran público la familiarización de estas imágenes (Martínez Vega, 1997).

CAPÍTULO 2

PRINCIPIOS FÍSICOS DE LA TELEDETECCIÓN

«Dos excesos: excluir la razón, y no admitir más que la razón.»

BLAISE PASCAL, *Pensamientos*

En el capítulo anterior se presentaban algunos aspectos introductorios de las técnicas analizadas en esta obra. En los dos próximos se van a exponer los procesos que permiten la adquisición de la imagen, para dedicar el resto a las tareas de interpretación. Para los científicos con preocupación por el medio ambiente, lo habitual será que estos últimos sean los que merezcan una mayor atención. Sin embargo, como es obvio, la interpretación de la imagen será tanto más rigurosa cuanto mayor conocimiento se tenga de los procesos que permitieron adquirirla.

1. Fundamentos de la observación remota

Anteriormente se definió la teledetección como aquella técnica que nos permite obtener información a distancia de los objetos situados sobre la superficie terrestre. Para que esta observación remota sea posible es preciso que entre los objetos y el sensor exista algún tipo de interacción. Nuestros sentidos perciben un objeto sólo cuando pueden descifrar la información que éste les envía. Por ejemplo, somos capaces de ver un árbol porque nuestros ojos reciben y traducen convenientemente una energía luminosa procedente del mismo. Esa señal, además, no es originada por el árbol, sino por un foco energético exterior que lo ilumina. De ahí que no seamos capaces de percibir ese árbol en plena oscuridad.

Este sencillo ejemplo nos sirve para introducir los tres principales elementos de cualquier sistema de teledetección: sensor (nuestro ojo), objeto observado (árbol) y flujo energético que los pone en relación y permite, en última instancia, detectar el objeto. En nuestro ejemplo, ese flujo procede del árbol por reflexión de la luz solar. Podría también tratarse de un tipo de energía emitida por el propio objeto (en caso de que fuéramos capaces de detectar el calor que emite), o incluso por el sensor (por ejemplo, si tuviéramos una cámara equipada con *flash*). Éstas son, precisamente, las tres formas

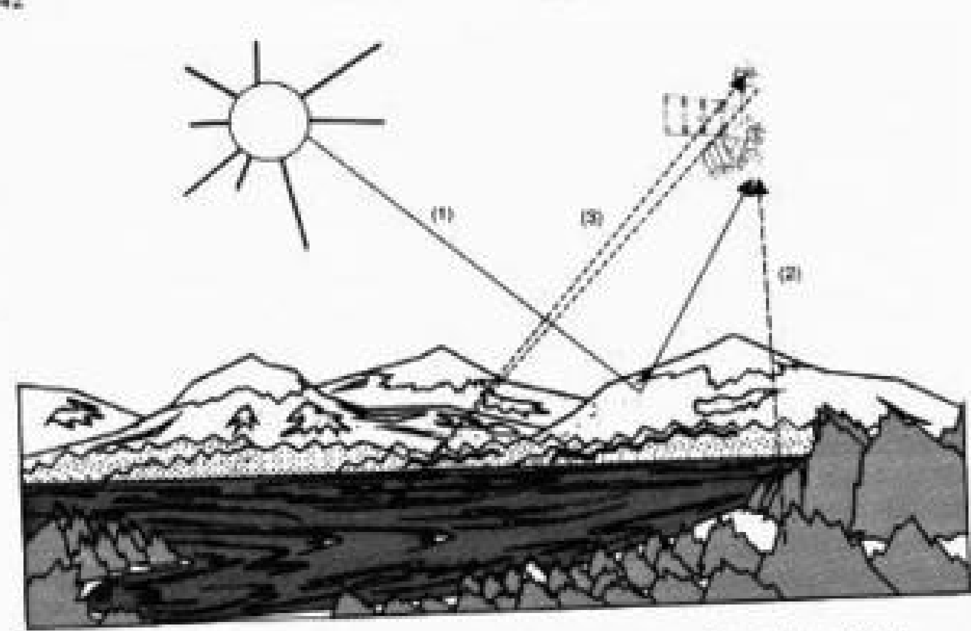


FIG. 2.1. *Formas de teledetección: (1) reflexión; (2) emisión; (3) emisión-reflexión.*

de adquirir información a partir de un sensor remoto: por reflexión, por emisión y por emisión-reflexión (fig. 2.1).

La primera de ellas es la forma más importante de teledetección, pues se deriva directamente de la luz solar, principal fuente de energía de nuestro Planeta. El sol ilumina la superficie terrestre, que refleja esa energía en función del tipo de cubierta presente sobre ella. Ese flujo reflejado se recoge por el sensor, que lo transmite posteriormente a las estaciones receptoras. Entre superficie y sensor se interpone la atmósfera, que dispersa y absorbe parte de la señal original. De igual forma, la observación remota puede basarse en la energía emitida por las propias cubiertas, o en la que podríamos enviar desde un sensor que fuera capaz, tanto de generar su propio flujo energético, como de recoger posteriormente su reflexión sobre la superficie terrestre.

En cualquiera de estos casos, el flujo energético entre la cubierta terrestre y el sensor constituye una forma de radiación electromagnética. Como es sabido, la energía se transfiere de un lugar a otro por tres procesos: convección, conducción y radiación. De ellos, nos centraremos en este último, pues constituye la base de los sistemas de teledetección analizados en esta obra.

Históricamente, las propiedades de la radiación electromagnética se han explicado por dos teorías aparentemente contrapuestas: aquella que la concibe como un haz ondulatorio (Huygens, Maxwell), y aquella otra que la considera como una sucesión de unidades discretas de energía, fotones o cuantos, con masa igual a cero (Planck, Einstein). Actualmente, parece que las dos teorías se pueden compaginar, pues se ha demostrado que la luz presenta comportamientos que pueden explicarse de acuerdo a ambos planteamientos.

Según la teoría ondulatoria, la energía electromagnética se transmite de un lugar

a otro siguiendo un modelo armónico y continuo, a la velocidad de la luz y conteniendo dos campos de fuerzas ortogonales entre sí: eléctrico y magnético (fig. 2.2). Las características de este flujo energético pueden describirse por dos elementos: longitud de onda (λ) y frecuencia (ν). La primera hace referencia a la distancia entre dos picos sucesivos de una onda, mientras que la frecuencia designa el número de ciclos pasando por un punto fijo en una unidad de tiempo. Ambos elementos están inversamente relacionados:

$$c = \lambda \nu \qquad [2.1]$$

donde c indica la velocidad de la luz (3×10^8 m s^{-1}), λ expresa la longitud de onda (habitualmente en micrómetros, 1 μm = 10^{-6}m o nanómetros, 1 nm = 10^{-9} m) y ν la frecuencia (en Hertzs, 1 Hz = 1 ciclo por segundo). En definitiva, a mayor longitud de onda, menor frecuencia y viceversa, por lo que basta con indicar un solo término para identificar propiamente el tipo de energía mencionado.

Gracias a la teoría cuántica podemos calcular la cantidad de energía transportada por un fotón, siempre que se conozca su frecuencia:

$$Q = h \nu \qquad [2.2]$$

donde Q es la energía radiante de un fotón (en julios), ν la frecuencia y h la constante de Planck ($6{,}6 \times 10^{-34}$ J s). Sustituyendo en [2.1], podemos asimismo expresar:

$$Q = h(c/\lambda) \qquad [2.3]$$

lo que significa, en definitiva, que a mayor longitud de onda —o menor frecuencia— el contenido energético será menor y viceversa. Esto implica que la radiación en longitudes de onda largas es más difícil de detectar que aquella proveniente de longitudes cortas, de ahí que las primeras requieran medios de detección más refinados.

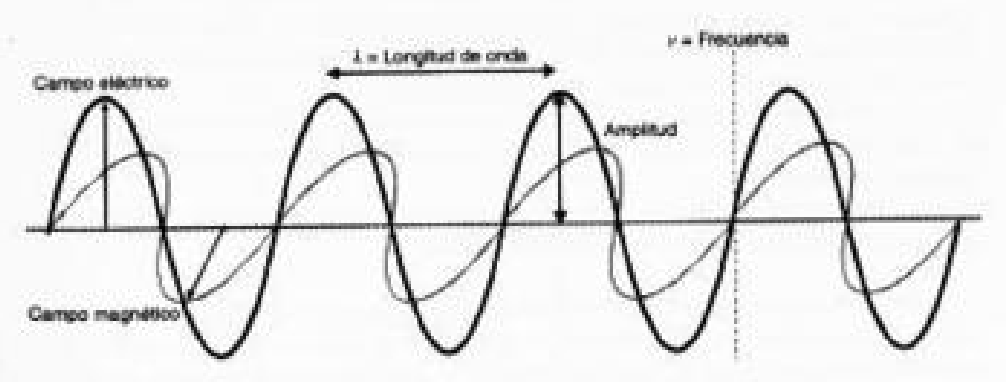


FIG. 2.2. *Esquema de una onda electromagnética.*

2. El espectro electromagnético

De las fórmulas anteriores se deduce que podemos definir cualquier tipo de energía radiante en función de su longitud de onda o frecuencia. Aunque la sucesión de valores de longitud de onda es continua, suelen establecerse una serie de bandas en donde la radiación electromagnética manifiesta un comportamiento similar. La organización de estas bandas de longitudes de onda o frecuencia se denomina espectro electromagnético (fig. 2.3). Comprende desde las longitudes de onda más cortas (rayos gamma, rayos X), hasta las kilométricas (tele-comunicaciones). Las unidades de medida más comunes se relacionan con la longitud de onda. Para las más cortas se utilizan micrómetros, mientras las más largas se miden en centímetros o metros. Normalmente a estas últimas (denominadas micro-ondas) se las designa también por valores de frecuencia (en Gigahertzs, GHz = 10^9 Hz).

Desde el punto de vista de la teledetección, conviene destacar una serie de bandas espectrales, que son las más frecuentemente empleadas con la tecnología actual. Su denominación y amplitud varían según distintos autores, si bien la terminología más común es la siguiente:

— Espectro visible (0,4 a 0,7 μm). Se denomina así por tratarse de la única radiación electromagnética que pueden percibir nuestros ojos, coincidiendo con las longitudes de onda en donde es máxima la radiación solar. Dentro de esta región suelen distinguirse tres bandas elementales, que se denominan azul (A, 0,4-0,5 μm), verde (V, 0,5-0,6 μm), y rojo (R, 0,6-0,7 μm), en razón de los colores primarios que nuestros ojos perciben a esas longitudes de onda.

— Infrarrojo cercano (IRC, 0,7-1,3 μm). También se denomina infrarrojo próximo, reflejado o fotográfico, puesto que parte de él puede detectarse a partir de películas dotadas de emulsiones especiales. Como veremos luego, resulta de especial importancia por su capacidad para discriminar masas vegetales y concentraciones de humedad.

— Infrarrojo medio (1,3 a 8 μm). En esta región se entremezclan los procesos de reflexión de la luz solar y de emisión de la superficie terrestre. La primera banda se sitúa entre 1,3 y 2,5 μm, y se denomina infrarrojo de onda corta (*Short Wave Infrared*, SWIR), que resulta idónea para estimar el contenido de humedad en la vegetación o los suelos. La segunda, comprendida principalmente en torno a 3,7 μm, se conoce propiamente como infrarrojo medio (IRM), siendo determinante para la detección de focos de alta temperatura (incendios o volcanes activos).

— Infrarrojo lejano o térmico (IRT, 8 a 14 μm), que incluye la porción emisiva del espectro terrestre, en donde se detecta el calor proveniente de la mayor parte de las cubiertas terrestres.

— Micro-ondas (M, por encima de 1 mm), con gran interés por ser un tipo de energía bastante transparente a la cubierta nubosa.

Más adelante se estudiará el comportamiento espectral de las principales cubiertas terrestres en cada una de estas bandas del espectro. Antes de ello convendrá introducir algunos conceptos y unidades de medida comúnmente empleados en teledetección.

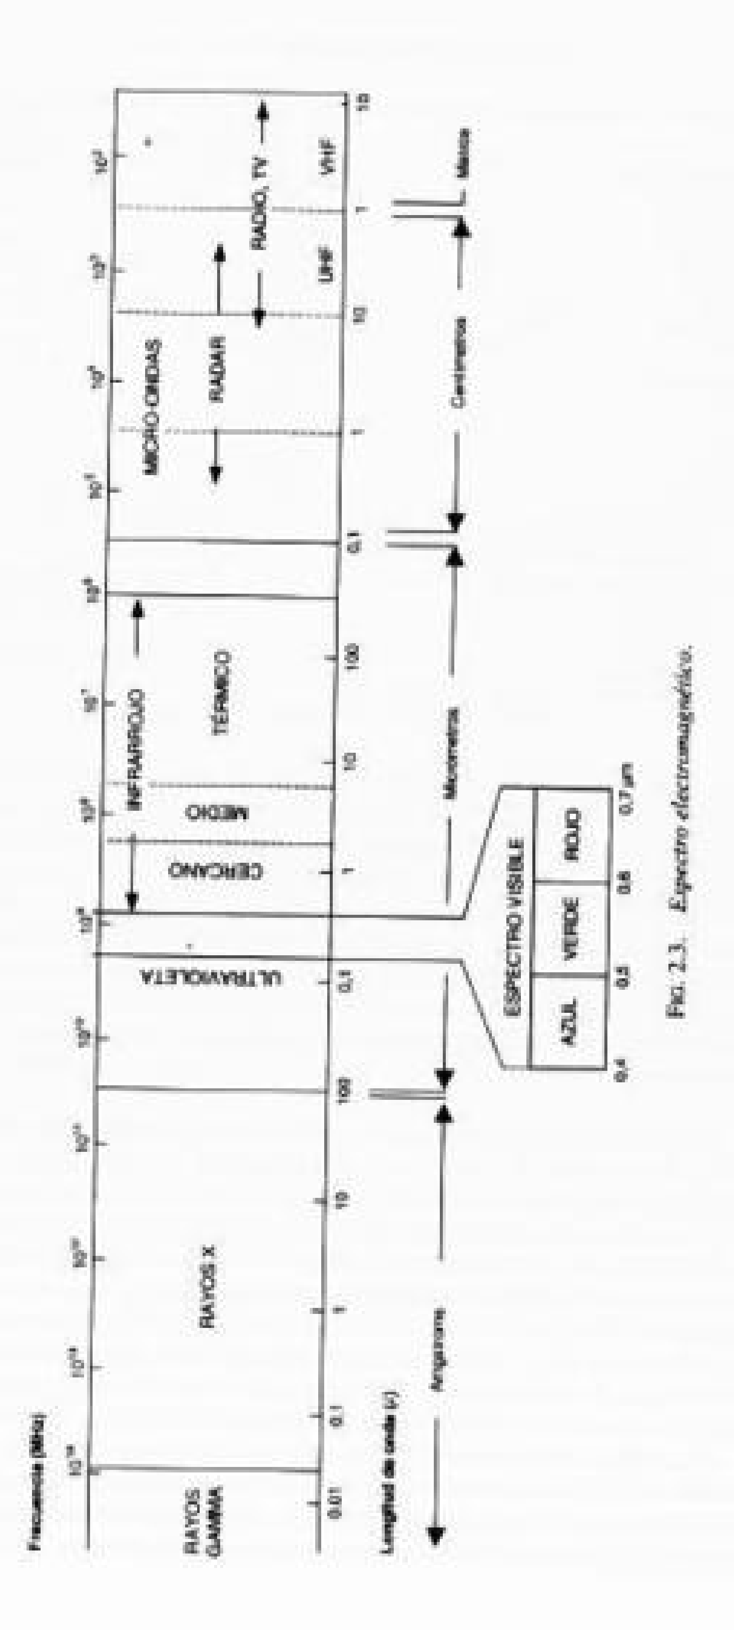


FIG. 2.3. *Espectro electromagnético.*

TABLA 2.1. *Magnitudes radiométricas comúnmente utilizadas en teledetección*

Concepto	*Símbolo*	*Fórmula*	*Unidad de medida*
Energía radiante	Q	—	Julios (J)
Flujo radiante	ϕ	$\delta Q/\delta t$	Vatios (W)
Emitancia	M	$\delta\phi/\delta A$	Wm^{-2}
Irradiancia	E	$\delta\phi/\delta A$	Wm^{-2}
Intensidad radiante	I	$\delta\phi/\delta\Omega$	Wsr^{-1}
Radiancia	L	$\delta\phi/\delta A \cos\theta$	$Wm^{-2}\ sr^{-1}$
Radiancia espectral	L_λ	$\delta L/\delta_\lambda$	$Wm^{-2}\ sr^{-1}\ \mu m^{-1}$
Emisividad	ε	M/M_n	
Reflectividad	ρ	ϕ_r/ϕ_i	
Absortividad	α	ϕ_a/ϕ_i	
Transmisividad	τ	ϕ_t/ϕ_i	

sr: Estéreo-radián, medida del ángulo sólido.
μm: micrómetro o micra (10^{-6} metros).
M_n: Emitancia de un cuerpo negro a la misma temperatura.
ϕ_i: flujo incidente.
ϕ_r: flujo reflejado.
ϕ_a: flujo absorbido.
ϕ_t: flujo transmitido.
θ: ángulo formado por el flujo y la dirección normal.

3. Términos y unidades de medida

Como más arriba se indicó, para que pueda producirse una observación remota de la superficie terrestre es preciso que el sensor detecte un flujo energético proveniente de ésta. Ese flujo tiene una intensidad determinada, proveniente de, o dirigida a, una unidad de superficie y con una dirección concreta. Convendrá, por tanto, explicitar las unidades de medida más empleadas en teledetección, con objeto de ser rigurosos a la hora de presentar posteriormente los procesos de adquisición. La formulación precisa de cada una de estas magnitudes se presenta en la tabla 2.1 (Curran, 1985; Elachi, 1987; Rees, 1999; Slater, 1980):

— *Energía radiante (Q).* Indica el total de energía radiada en todas las direcciones. Se mide en julios (J).
— *Flujo radiante (φ).* Total de energía radiada en todas las direcciones por unidad de tiempo. Se mide en vatios (W).
— *Emitancia o excitancia radiante (M).* Total de energía radiada en todas las direcciones *desde* una unidad de área y por unidad de tiempo. Se mide en vatios por metro cuadrado (Wm^{-2}).
— *Irradiancia (E).* Total de energía radiada *sobre* una unidad de área y por unidad de tiempo. Es equivalente a la emitancia, si bien ésta indica la energía emitida, mientras la irradiancia refiere a la incidente (Wm^{-2}).
— *Intensidad radiante (I).* Total de energía radiada por unidad de tiempo y por ángulo sólido (Ω). Se trata éste de un ángulo tridimensional, que refiere a la sección completa de la energía transmitida, y se mide en estéreo-radianes (fig. 2.4). Por tanto la intensidad radiante se mide en vatios por estéreo-radián (Wsr^{-1}).

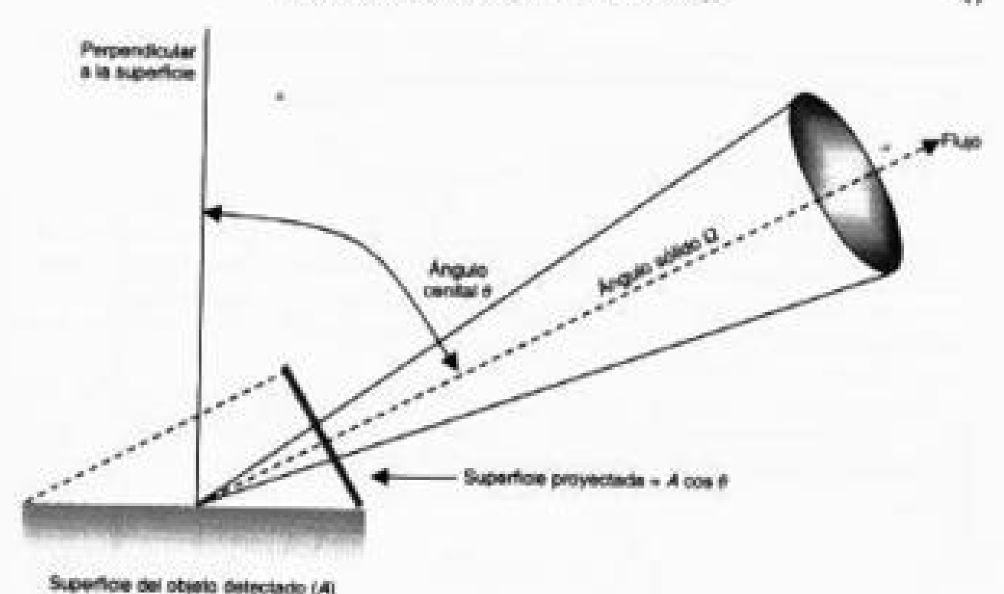


FIG. 2.4. *Diagrama de un ángulo sólido.*

— *Radiancia (L).* Total de energía radiada en una determinada dirección por unidad de área y por ángulo sólido de medida. Es un término fundamental en teledetección, ya que describe precisamente lo que mide el sensor. Se cuantifica en vatios por metro cuadrado y estéreo-radián ($W/m^{-2}\ sr^{-1}$).
— *Radiancia espectral (L_λ).* Por extensión del concepto anterior, indica el total de energía radiada en una determinada longitud de onda por unidad de área y por ángulo sólido de medida. Por cuanto el sensor detecta una banda particular del espectro, ésta es la medida más cercana a la observación remota. De igual forma que la radiancia, la emitancia e irradiancia pueden completarse con el calificativo de espectral (añadiendo el subíndice λ), cuando se refieren a una determinada longitud de onda.
— *Emisividad (ε).* Relación entre la emitancia de una superficie (*M*), y la que ofrecería un emisor perfecto, denominado cuerpo negro, a la misma temperatura (M_n).
— *Reflectividad (ρ).* Relación entre el flujo incidente y el reflejado por una superficie.
— *Absortividad (α).* Relación entre el flujo incidente y el que absorbe una superficie.
— *Transmisividad (τ).* Relación entre el flujo incidente y el transmitido por una superficie.

Estos últimos términos son adimensionales; suelen expresarse en tantos por ciento o por uno. Por esta razón, hemos traducido los términos ingleses: *emittance, reflectance, absorptance* y *transmittance*, añadiendo el sufijo «ividad», para indicar que son cantidades relativas, distinguiéndolas así de las anteriores, que son absolutas (de ahí el sufijo «ancia»). También estas magnitudes son dependientes de la longitud de onda,

por lo que conviene completarlas con el calificativo de espectral, para referirse a su comportamiento en una banda determinada del espectro.

4. Principios y leyes de la radiación electromagnética

El objeto de este capítulo es caracterizar espectralmente las distintas cubiertas de interés medio ambiental. Para ello resulta obligado comentar los procesos más importantes que permiten explicar ese comportamiento, así como los factores que intervienen en su variación. Esta base permitirá abordar una interpretación más rigurosa de la imagen finalmente obtenida por el sensor.[1]

De acuerdo a la fórmula [2.3], la cantidad de energía que contiene un flujo radiante es inversamente proporcional a su longitud de onda. Esta relación entre flujo de energía y longitud de onda puede establecerse con mayor rigor gracias a la ley de Planck:

$$M_{n,\lambda} = \frac{2\pi hc^2}{\lambda^5\left\{\exp\dfrac{hc}{\lambda kT} - 1\right\}} \qquad [2.4]$$

donde $M_{n,\lambda}$ indica la emitancia radiativa espectral de un cuerpo negro a una determinada longitud de onda (λ); h es la constante de Planck ($6{,}626 \times 10^{-34}$ W s²); k, la constante de Boltzmann ($1{,}38 \times 10^{-23}$ W s² K^{-1}); c, la velocidad de la luz; λ, la longitud de onda, y T, la temperatura absoluta de un cuerpo negro (en Kelvin, K). Esta fórmula se puede simplificar sustituyendo algunos términos por constantes:

$$M_{n,\lambda} = \frac{c_1}{\lambda^5\left\{\exp\dfrac{c_2}{\lambda T} - 1\right\}} \qquad [2.5]$$

donde c_1 puede sustituirse por $3{,}741 \times 10^8$ W m^{-2} μm^4 y c_2 por $1{,}438 \times 10^4$ μm K.

En pocas palabras, la fórmula de Planck nos señala que cualquier objeto por encima del cero absoluto (−273 °C) radia energía, y que ésta aumenta con la temperatura. A la vez, a mayor temperatura, ese cuerpo radiará con más intensidad en longitudes de onda más cortas. De esta fórmula podemos reconstruir la curva de emitancia de un cuerpo negro a distintas temperaturas (fig. 2.5). El gráfico es muy interesante para conocer el comportamiento radiativo de un objeto, siempre que conozcamos su temperatura y su emisividad; esto es, su grado de similitud con un cuerpo negro.

A partir de la fórmula de Planck puede calcularse la longitud de onda a la que se produce la máxima emitancia de un cuerpo negro conociendo su temperatura. Ésta es la llamada ley del desplazamiento de Wien:

1. El lector interesado en una mayor profundización en estos principios físicos puede consultar otros manuales más especializados como los de Asrar (1989), Slater (1980) o Sobrino (2000).

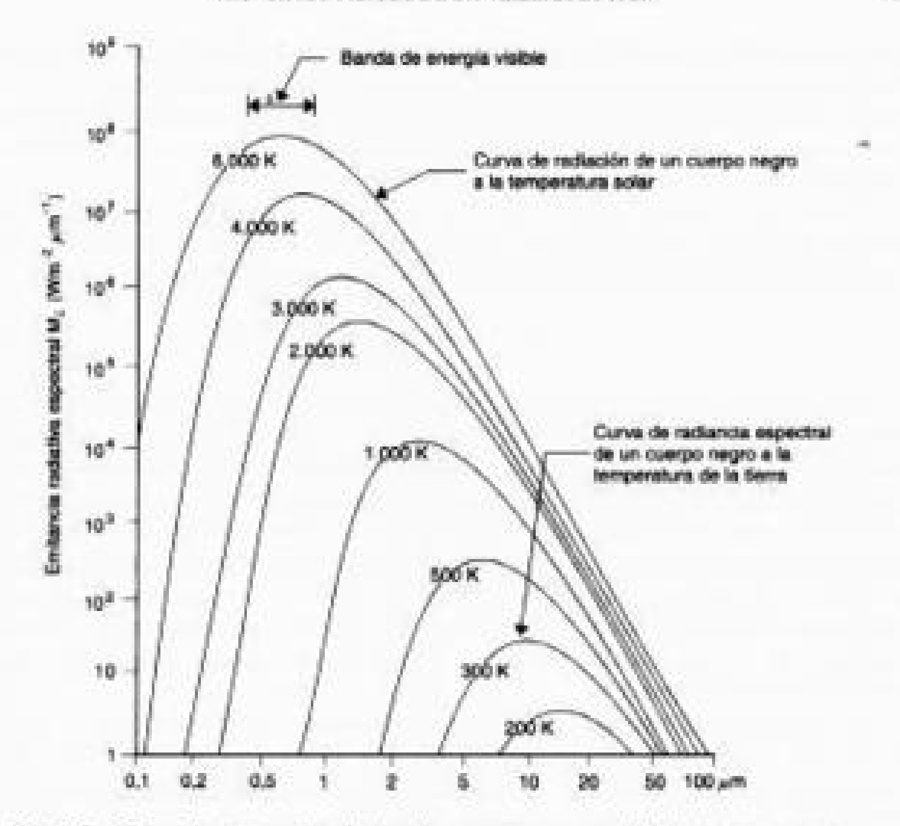


FIG. 2.5. *Curva de emitancia radiativa de un cuerpo negro a distintas temperaturas.*

$$\lambda_{max} = \frac{2.898}{T}\,\mu\text{m K} \qquad [2.6]$$

donde la temperatura (T) está expresada en Kelvin. Esta ley tiene una gran importancia para seleccionar la banda más conveniente para detectar un objeto a una determinada temperatura. Por ejemplo, si asumimos que un incendio forestal presenta una temperatura de combustión próxima a los 800 K, la ley de Wien nos permite situar en 3,6 μm (IRM) la banda espectral más adecuada para su detección. Por su parte, el sol —con una temperatura radiante próxima a los 6.000 K— presenta su máxima emitancia en la región del espectro visible (0,4 a 0,7 μm).

Integrando la emitancia espectral de un cuerpo negro para todas las longitudes de onda, podemos calcular el total de energía que radia por unidad de superficie. Ésta es la ley de Stefan-Boltzmann:

$$M_n = \sigma T^4 \qquad [2.7]$$

donde σ es la constante de Stefan-Boltzmann ($5{,}67 \times 10^{-8}$ W m^{-2} K^{-4}), y T la temperatura en Kelvin. A consecuencia de esta fórmula resulta evidente que la emitancia

global de un objeto es una función de su temperatura, y que pequeños cambios en ésta suponen notables modificaciones en su emitancia radiante. Por otra parte, conociendo la temperatura de un objeto emisor, podemos también estimar la irradiancia incidente sobre el sensor, por cuanto emitancia e irradiancia son funcionalmente equivalentes.

Hasta aquí hemos supuesto que las superficies naturales se comportan como cuerpos negros, lo que implica una notable simplificación. Por ello se han de corregir las fórmulas anteriores añadiendo un nuevo parámetro, la emisividad:

$$M = \varepsilon M_n \qquad [2.8]$$

La emisividad ya se definió como el grado de similitud entre la emitancia radiante de un objeto y la que presentaría un cuerpo negro a la misma temperatura. Un cuerpo negro indica un emisor perfecto; esto es, un objeto que absorbe y emite toda la energía que recibe. Se habla de cuerpos blancos o reflectores perfectos cuando no absorben nada de la energía incidente, sino que la reflejan por completo (emisividad = 0), mientras serían cuerpos grises aquellos objetos que absorben y emiten de forma constante en distintas longitudes de onda. Cuando la emisividad varía con la longitud de onda se emplea el término de radiadores selectivos. Son los más frecuentes en la naturaleza. Gracias a ese comportamiento particular pueden discriminarse de otro tipo de superficies en el infrarrojo térmico.

A partir de las fórmulas [2.4 a 2.8] podemos estimar la emitancia total y espectral de un objeto conociendo su temperatura absoluta, siendo aquélla tanto mayor cuanto más alta sea ésta. En definitiva, la energía emitida desde un objeto es primariamente una función de su temperatura. Pequeños cambios en ésta suponen una modificación sensible de la emitancia total, de acuerdo a [2.7]. Además, conociendo la temperatura de un objeto o cubierta de interés —y dado que pueda estimarse su emisividad—, será posible determinar la banda del espectro más idónea para su discriminación.

Con estas nociones puede abordarse el comentario más detallado de las tres regiones del espectro en donde se realizan procesos de teledetección: longitudes de onda cortas (desde el visible al SWIR), medias (IRM y térmico) y largas (micro-ondas).

5. El dominio óptico del espectro

5.1. Características de la radiación energética en el espectro óptico

Denominamos dominio óptico del espectro a aquel grupo de longitudes de onda directamente dependientes de la energía solar, comprendidas entre el visible y el SWIR (0,4 a 2,5 μm).

Para una mejor comprensión de estas bandas espectrales conviene analizar con más detenimiento en este apartado las características espectrales del sol, fuente primordial de energía radiante en nuestro planeta. Más adelante nos detendremos a analizar el comportamiento de las principales coberturas terrestres frente a este tipo de radiación.

El sol se encuentra a una temperatura radiante próxima a los 6.000 K. Esto impli-

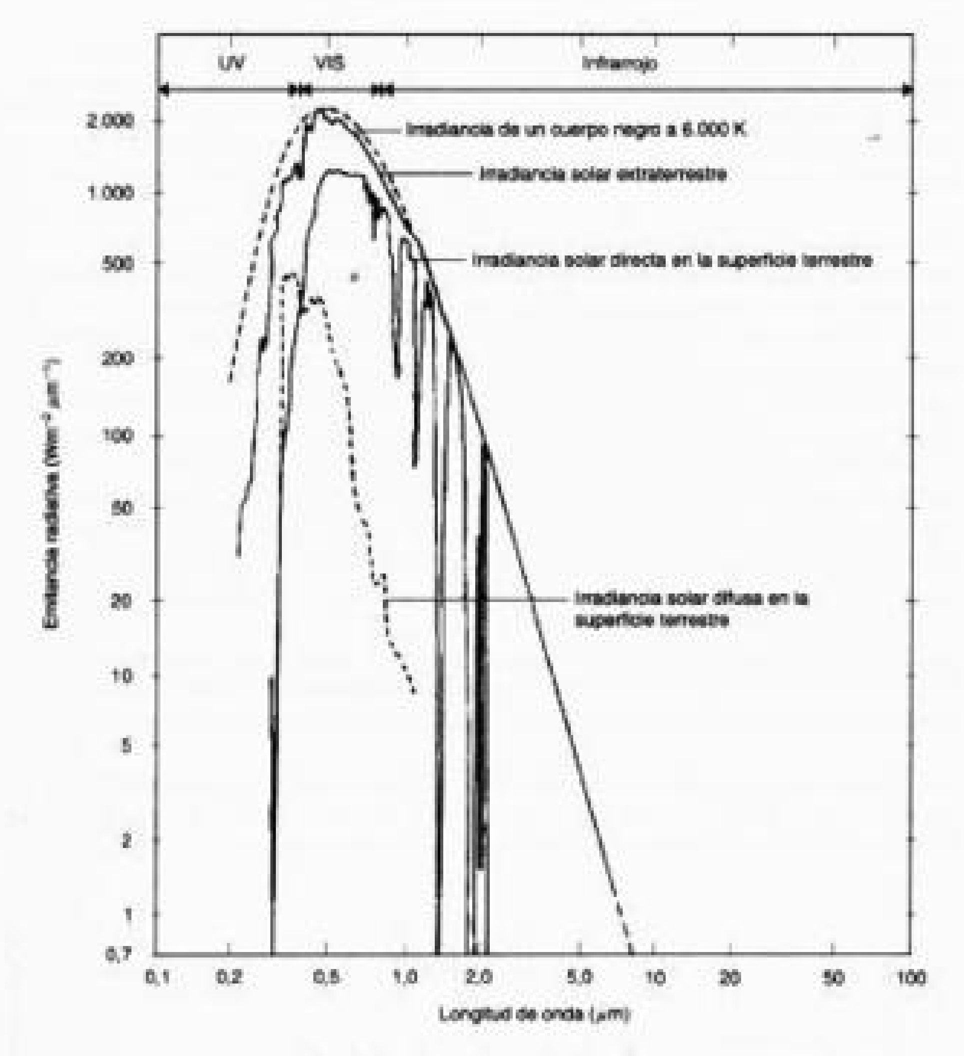


FIG. 2.6. *Curva de emitancia solar.*

ca, según la ley de Wien, que su máxima emitancia espectral se produce en torno a las 0,48 μm, coincidente con el color verde apreciado por nuestros ojos. La curva espectral de la radiación solar se asemeja bastante a la de un cuerpo negro a esa temperatura, tal y como aparece en la figura 2.6. En este gráfico se observa cómo el sol presenta una banda de elevada emitancia entre 0,3 y 2,5 μm, de ahí que éstas sean las longitudes de onda más dependientes de su iluminación.

Hasta aquí se ha considerado el origen de la radiación. Más importante aún para nuestro objetivo es entender cómo este flujo interacciona con la superficie terrestre. La radiación que ésta recibe puede descomponerse en tres términos (fig. 2.7):

$$\phi_i = \phi_r + \phi_a + \phi_t \qquad [2.9]$$

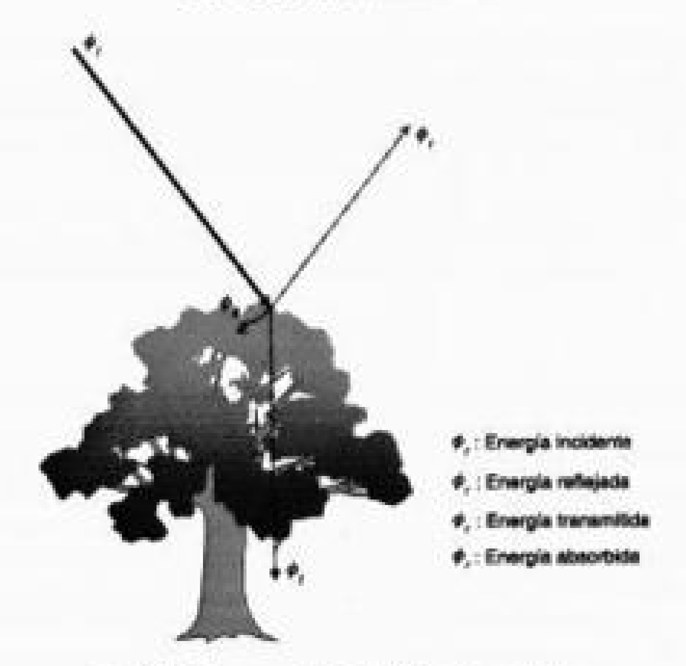


FIG. 2.7. *Descomposición del flujo solar incidente.*

Esto es, el flujo incidente sobre una superficie es reflejado (ϕ_r), transmitido (ϕ_t) o absorbido (ϕ_a). Resulta conveniente expresar esta fórmula en unidades relativas. Para ello, basta dividir cada término de la expresión anterior por ϕ_i:

$$\frac{\phi_i}{\phi_i} = \frac{\phi_r}{\phi_i} + \frac{\phi_a}{\phi_i} + \frac{\phi_t}{\phi_i} \qquad [2.10]$$

o, lo que es lo mismo:

$$1 = \rho + \alpha + \tau \qquad [2.11]$$

En definitiva, la suma de la reflectividad, absortividad y transmisividad ha de ser igual a uno. La relación entre las tres magnitudes no es constante, sino que varía con la longitud de onda (λ); por tanto, en términos más rigurosos, debería expresarse como:

$$1 = \rho_\lambda + \alpha_\lambda + \tau_\lambda \qquad [2.12]$$

La proporción del flujo incidente que es reflejado, absorbido y transmitido depende de las características de la superficie que se observa y de la longitud de onda a la que sea observado. Para poder caracterizar una determinada cubierta nos resulta muy interesante conocer su comportamiento reflectivo en diversas longitudes de onda, ya que esto facilitará discriminarlo frente a cubiertas espectralmente similares.

En el caso del espectro visible, ese comportamiento disimilar de los objetos a distintas longitudes de onda se manifiesta en lo que llamamos color: un objeto es azul si refleja intensamente la energía en esa banda del espectro y poco en el resto (dicho de otro modo, si absorbe o transmite poca energía incidente sólo en el azul, siendo mayor la absorción en el resto), mientras será verde si su reflectividad se centra en esa banda y es baja en otras.

A partir de medidas de laboratorio puede obtenerse unas curvas de reflectividad espectral para las principales cubiertas terrestres, que suelen denominarse signaturas o firmas espectrales (fig. 2.8). Como puede observarse, algunas cubiertas tienden a presentar una respuesta uniforme en distintas longitudes de onda, mientras otras ofrecen un comportamiento mucho más selectivo. Por ejemplo, la nieve presenta una reflectividad alta y constante en las bandas cortas (hasta el IRC), pues refleja la mayor parte de la energía incidente en esas longitudes de onda. Por el contrario, el agua absorbe la mayor parte de la energía que recibe, tanto más según nos situamos en longitudes de onda mayores. Por su parte, la vegetación presenta un comportamiento muy cromático, con bajos valores de reflectividad en el espectro visible, más elevados en el infrarrojo cercano y menores en el medio. Finalmente, los materiales de construcción poseen un comportamiento más similar a distintas longitudes de onda.

Más adelante se analizarán con detalle estos valores típicos de reflectividad para el caso de la vegetación, agua y suelo. Antes de ello es importante considerar que el flujo de energía recibido por el sensor, no sólo depende de la reflectividad de la cubier-

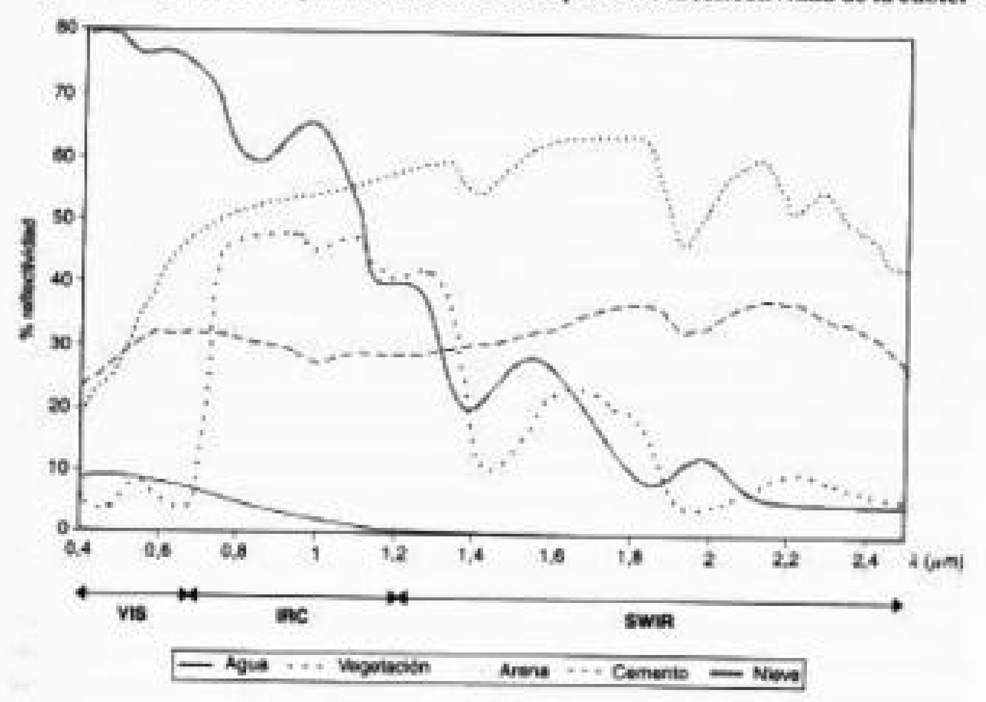


FIG. 2.8. *Signaturas espectrales típicas para distintas cubiertas (datos adquiridos con un espectro-radiómetro GER-2600).*

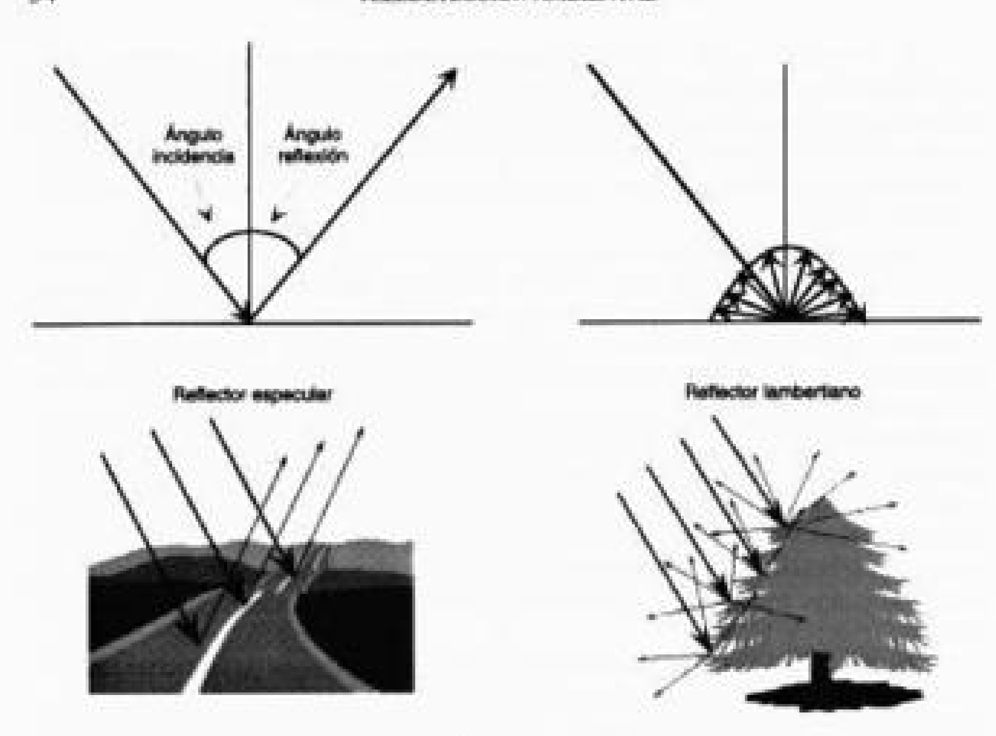


FIG. 2.9. *Tipos de comportamiento reflectivo.*

ta, sino también de otros factores externos. Los más importantes son: 1) las condiciones atmosféricas, 2) el emplazamiento ambiental de la cubierta, y 3) la geometría de la observación.

Los dos primeros aspectos se tratarán más adelante. En cuanto a las condiciones de observación, conviene tener presente que la cantidad de energía que llega al sensor depende del ángulo con que la superficie refleje la energía incidente, así como del que formen el haz incidente con la posición del sensor. Esta geometría de observación está estrechamente ligada a la rugosidad que presenta la superficie. A este respecto, pueden distinguirse dos tipos de cubiertas (fig. 2.9): aquellas que reflejan la energía con el mismo ángulo del flujo incidente (especulares), y aquellas que lo reflejan uniformemente en todas las direcciones (lambertianas). En el primer caso, el sensor sólo recibe energía reflejada del suelo si está situado en la dirección del ángulo de reflexión, siendo nula en cualquier otro caso. Si la superficie es lambertiana, la radiancia es constante en cualquier ángulo de reflexión. La mayor parte de las cubiertas tienden a comportarse de modo intermedio entre ambas situaciones, en función de sus características y de la longitud de onda en la que se trabaje. Si la longitud de onda es pequeña, las rugosidades del terreno tenderán a difundir mucho más la energía incidente que si se trata de longitudes de onda mayores, en donde esos rasgos pueden no impedir un comportamiento especular. En el espectro visible, por ejemplo, sólo el agua en calma presenta un carácter casi especular, mientras el resto de las cubiertas tienden a ofrecen un comportamiento difuso. En longitudes de onda mayores (micro-ondas), también otras cu-



biertas pueden comportarse de modo especular, siempre que la rugosidad del terreno sea suficientemente pequeña. En general, los modelos para el cálculo de reflectividad tienden a asumir que las cubiertas presentan un comportamiento lambertiano, ya que esto simplifica mucho los cálculos al ser independientes de los ángulos de observación (cap. 6, apdo. 6.2.3). En la práctica, la mayor parte de las superficies presentan una clara reflectividad direccional, esto es, la reflexión es más intensa en ciertas direcciones, por lo que se intenta considerar este factor en los modelos de cálculo más avanzados.[2]

En cualquier caso, el ángulo de iluminación solar y el ángulo de observación juegan un papel muy destacado en la respuesta finalmente obtenida por el sensor. En pocas palabras, el sensor puede registrar un valor distinto de radiancia espectral para un mismo tipo de cubierta —con la misma o similar reflectividad— si varían las condiciones de observación o de iluminación. Además, es preciso tener en cuenta que una superficie vegetal puede presentar distintos grados de cobertura a lo largo del año, por lo que podríamos hablar incluso de una signatura espectro-temporal, que permitiría mejorar la discriminación de una determinada cubierta siguiendo su dinamismo estacional (Robin, 1998).

Considerar todos estos factores subraya la complejidad que la observación remota lleva consigo, ya que el comportamiento de una cubierta en el espectro visible está influido no sólo por sus propias características, sino también por una serie de factores externos que modifican lo que podríamos llamar su comportamiento espectral teórico. Algunos de estos factores son (fig. 2.10):

— Ángulo de iluminación solar (1), muy dependiente de la fecha del año y del momento de paso del satélite.
— Modificaciones que el relieve introduce en el ángulo de iluminación: orientación de las laderas (2) o pendiente (3).
— Influencia de la atmósfera, especialmente en lo que se refiere a la absorción por nubes (4) y a la dispersión selectiva en distintas longitudes de onda.
— Variaciones medio ambientales en la cubierta: asociación con otras superficies, homogeneidad que presenta, estado fenológico (5), etc.
— Sustrato edafológico o litológico (6), especialmente influyente cuando la cubierta observada presenta una densidad media.

A ello habría que añadir que la radiación incidente en una determinada superficie no sólo es la directa solar, sino también la proveniente de superficies vecinas o de la propia atmósfera, ya que las reflexiones se producen en múltiples direcciones. Este fenómeno, conocido como irradiancia difusa, tiene gran importancia en áreas de baja iluminación, como veremos más adelante.

Estos factores expresan la complejidad que puede entrañar la caracterización de un tipo de cubierta a partir de sensores remotos. También nos sirven para matizar un tanto la validez de las curvas espectrales indicadas previamente, que no deben considerarse más que como reflectividades de referencia. Este modo peculiar con el que una

2. Habitualmente se denominan correcciones BRDF, como luego tendremos ocasión de analizar (cap. 6, apdo. 6.2.3.3).

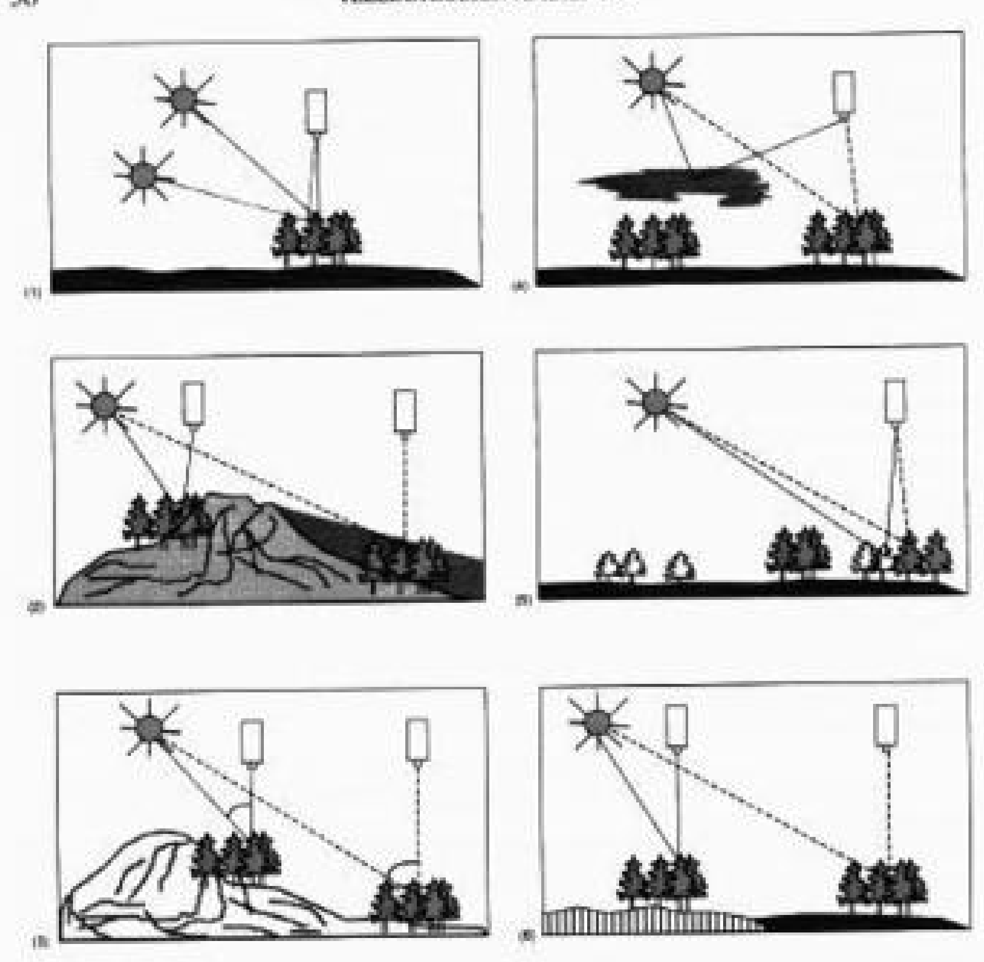


FIG. 2.10. *Factores que modifican la signatura espectral: (1) variaciones en la altura solar; (2) orientación de la vertiente; (3) pendiente; (4) atmósfera; (5) condición fenológica; (6) sustrato edáfico.*

determinada cubierta refleja o emite energía a distintas longitudes de onda se ha denominada comúnmente firma o signatura espectral (Meliá *et al.*, 1986; Slater, 1980), y resulta la base para discriminar dicha cubierta de otras a partir de la observación remota. Ahora bien, como venimos comentando, además del comportamiento espectral propio de cada cubierta, es preciso considerar los factores arriba indicados, que modifican esa signatura característica. En suma, las distintas cubiertas de la superficie terrestre no tienen un comportamiento espectral único y permanente, que coincida con sus curvas de reflectividad espectral y permita reconocerlas sin confusión frente a otras superficies. Por el contrario, en torno a un comportamiento tipo, que denominamos signatura espectral, cada cubierta presenta una cierta variabilidad espectral, debida a los factores ya comentados, y que dificulta —en última instancia— su discriminación de otras superficies.

Pese a estos comentarios, no cabe duda que las curvas de reflectividad arriba ana-

lizadas son muy útiles para interpretar más fielmente la imagen, por cuanto relacionan los valores adquiridos por el sensor con las medidas de laboratorio o con las imágenes bien calibradas. A la vez, estas gráficas nos permiten seleccionar las bandas más convenientes para la detección de las cubiertas terrestres bajo estudio.

A continuación se analizan con mayor detalle los factores que explican este comportamiento espectral teórico para el caso de los tres elementos fundamentales del paisaje: vegetación, suelo y agua.

5.2. Comportamiento espectral de la vegetación en el espectro óptico

La caracterización espectral de las masas vegetales constituye una de las tareas más interesantes en teledetección. Pese a su gran importancia, aún ofrece notables dificultades como consecuencia de los múltiples factores que influyen en la radiancia final detectada por el sensor. Podemos dividir estos factores en tres grandes grupos (Belward, 1991; Colwell, 1974; Gausman, 1977; Guyot *et al.*, 1989; Sellers, 1989):

— Los relacionados con la reflectividad de la hoja, que suele ser el elemento más visible desde una plataforma espacial. Aquí los factores más destacados son la presencia de pigmentos, la estructura celular y el contenido de humedad.

— Las características geométricas de la planta, principalmente su área foliar, la forma de las hojas, su distribución en la planta, la geometría del dosel, la importancia del componente leñoso, etc.

— Finalmente, habría que considerar aquellos aspectos derivados de la situación geográfica de la planta: pendiente, orientación, asociación con otras especies, reflectividad del sustrato, geometría de plantación, condiciones atmosféricas, etc.

En lo que se refiere a la reflectividad de la hoja, podemos basarnos en estudios realizados a partir de espectro-radiómetros en laboratorio (Colwell, 1974; Curran, 1980; Gates *et al.*, 1965; Knipling, 1970; Lusch, 1989). Las curvas espectrales resultantes varían en relación con el tipo de hoja, si bien podemos establecer unos patrones generales, marcados por la baja reflectividad en el visible, alta en el IRC y baja, con presencia de algunos máximos relativos, en el SWIR (figs. 2.8 y 2.11).

En concreto, la baja reflectividad en la porción visible del espectro se debe al efecto absorbente de los pigmentos de la hoja, principalmente las clorofilas, xantofila y caroteno (65, 29 y 6 %, respectivamente, aunque la proporción puede variar mucho: Gates *et al.*, 1965). Todos ellos absorben en la banda del espectro situada en torno a los 0,445 μm, mientras la clorofila presenta una segunda banda de absorción en torno a los 0,645 μm. Entre ambas porciones del espectro aparece una banda intermedia, alrededor de los 0,55μm, en donde el efecto absorbente es menor. Por esta causa aparece un pico relativo de reflectividad que coincide con la banda verde del espectro visible, y causa el color con el que nuestros ojos perciben la vegetación vigorosa.

Cuando se aproxima la caída otoñal de las hojas, la clorofila ejerce una menor influencia, lo que explica su mayor reflectividad en la banda roja y, en definitiva, su color amarillento (verde + rojo). En algunas especies resulta destacada la acción de otro

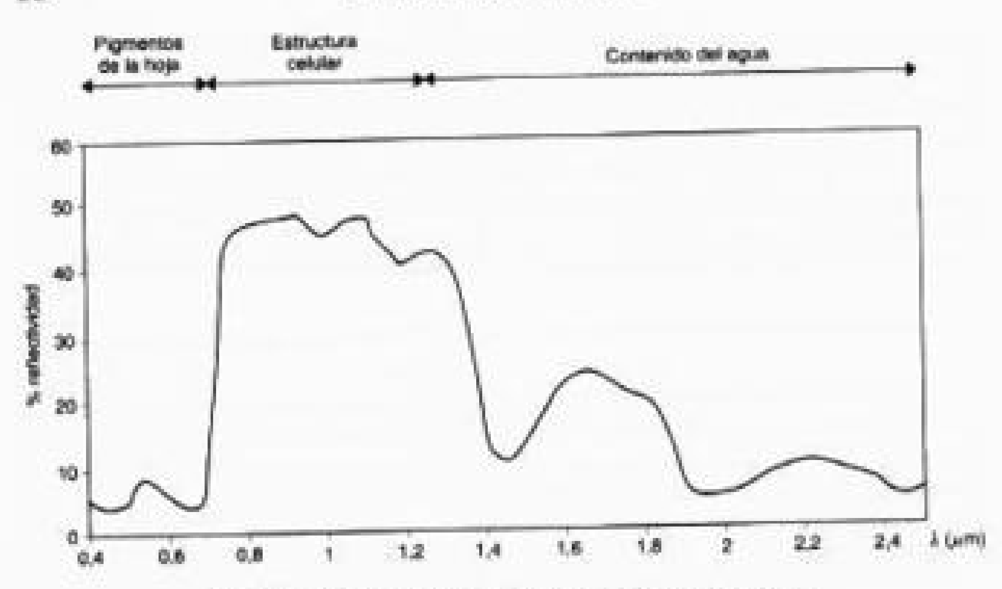


FIG. 2.11. *Factores que explican la reflectividad de la hoja.*

pigmento, la antocianina, buen reflector de la porción roja del espectro, que causa ese color en épocas de senescencia (caso de los arces canadienses o la lenga chilena).

La elevada reflectividad en el infrarrojo cercano se debe, por un lado, a la baja absortividad de las clorofilas, y, por otro, a la estructura celular interna de la hoja. Como es sabido, la hoja se compone, en esencia, de cuatro capas: las epidermis superior e inferior, el parénquima en empalizada y el mesófilo esponjoso. Las dos primeras juegan un importante papel en la regulación térmica de la planta y en su absorción de CO_2. El parénquima alberga los cloroplastos, mientras en el mesófilo tienen lugar los intercambios gaseosos necesarios para la respiración de la planta. Debido a ello, cuenta con unas cavidades de aire internas, que dispersan la mayor parte de la radiación incidente en esta banda del espectro (Gates *et al.*, 1965; Horler *et al.*, 1983). Por ello, la hoja sana ofrece una alta reflectividad en el infrarrojo cercano, en claro contraste con la baja reflectividad que presenta en el espectro visible, especialmente en la banda roja. Puesto que la estructura de la hoja es muy variada según las especies, esta banda también resulta idónea para discriminar entre plantas, incluso entre aquellas que no podrían separarse en el espectro visible.

A partir de 1,4 μm el efecto absorbente del agua es muy claro, por lo que la reflectividad de la vegetación sana se reduce drásticamente en el SWIR. Las medidas de laboratorio muestran una notable diferencia en esta región del espectro entre las hojas secas y las infiltradas con agua (Bowman, 1989; Hunt *et al.*, 1987). En experimentos con hojas de higuera, la reflectividad de la hoja seca alcanzó hasta cuatro veces el valor de la hoja húmeda, para la banda situada en torno a 1,9 μm (Short, 1982). En otros estudios sobre hojas de conífera se observó un sensible aumento de la reflectividad en el infrarrojo medio según se iban desecando las hojas, disminuyendo ligeramente en el infrarrojo cercano y con escasa variación en el visible (Westman y Price, 1988). En especies mediterráneas de matorral y arbolado también se han comprobado estas bue-

nas relaciones, de signo negativo, entre contenido de humedad y reflectividad en el SWIR (Riaño *et al.*, 2000; Vaughan, 2001: fig. 2.12). Entre estas bandas, donde la absorción del agua es más clara, se sitúan dos picos relativos de reflectividad, en torno a 1,6 μm y 2,2 μm. Queda patente, pues, que la observación en esta región del espectro es de gran interés para conocer el estado hídrico de la hoja.

Obviamente, el sensor no mide hojas aisladas, sino agrupaciones de hojas formando plantas o masas de vegetación, por lo que además de la reflectividad de la hoja es preciso tener en cuenta otros elementos adicionales que complican el esquema previo. Para no alargar excesivamente esta exposición conviene aquí citar tres grupos de factores: la geometría de la planta, los ángulos de observación e iluminación, y las características del sustrato. De ellos, tal vez el más destacado es la proporción hoja-suelo-lignina que observa el sensor, siendo la reflectividad de la planta más similar a la de la hoja cuando los porcentajes de cobertura son elevados y los ángulos de iluminación y observación verticales. Aunque el grado de cobertura verde del suelo (PV) es un parámetro clave en teledetección, habitualmente se maneja en su lugar el índice de área foliar (LAI), que cuenta con mayor trascendencia ecológica, ya que de alguna manera hace referencia a la productividad neta de la planta. El LAI se relaciona directamente con la PV hasta un cierto nivel de saturación (100 % de PV). Ese valor crítico se alcanza cuando el LAI se sitúan entre 3 y 6, según los ecosistemas. A partir de ahí puede seguir aumentando el LAI, aunque el PV ya se mantenga estable, como consecuencia del apilamiento vertical de las hojas (Sellers, 1987).

En los últimos años se han desarrollado diversos modelos de simulación de reflectividad (Goel, 1988; Huemmrich, 2001; Jacquemoud, 1990; Jacquemoud, 1993), que permiten analizar el impacto teórico de alterar alguno de los parámetros que afectan a la reflectividad de la hoja o del dosel vegetal. Para estos últimos, suelen introdu-

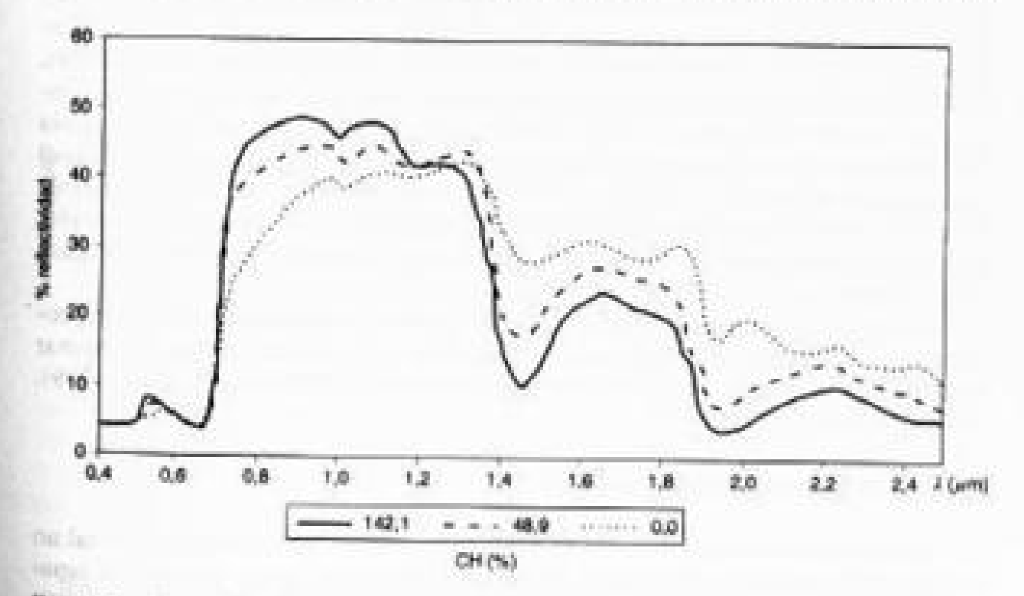


FIG. 2.12. *Curvas de reflectividad para hojas de jara* (Cistus ladanifer) *con distintos contenidos de humedad. (Datos adquiridos con un espectro-radiómetro GER-2600.)*

cirse como variables de entrada la reflectividad de la hoja, el LAI, la distribución geométrica de las hojas, y los ángulos de observación e iluminación (Barnsley y Hobson, 1997; Danson, 1998). Más adelante comentaremos con más detenimiento las posibilidades de estos modelos (cap. 7, apdo. 1.1).

Simplificando un poco las cosas, podemos resumir que la observación remota de las cubiertas vegetales puede apoyarse en el gran contraste cromático que presenta la vegetación vigorosa entre las distintas bandas del espectro, y singularmente entre el visible (alta absorción, baja reflectividad) y el *IRC* (alta reflectividad). De ahí que podemos enunciar, como principio genérico, que cuanto mayor sea el contraste entre esas bandas, mayor será el vigor de la vegetación, y más clara su discriminación frente a otros tipos de cubierta. Este comportamiento espectral teórico de las cubiertas vegetales ha sido la base para obtener una serie de índices de vegetación, que se basan precisamente en el contraste entre las bandas *R* e *IRC* del espectro. Se construyen a partir de la combinación entre estas dos bandas, cuando disponemos de una imagen multi-espectral. Muy variados en su desarrollo, todos ellos tienden a presentar de forma más nítida las características de la vegetación, facilitando su aislamiento de otras cubiertas y la detección de su estado vital (Bannari *et al.*, 1995; Curran, 1981; Myneni *et al.*, 1995; Sellers, 1989). Más adelante se estudiará el interés temático de estas transformaciones (7.1.2).

Queda implícito que cualquier fuente de estrés en la vegetación se mostrará en un comportamiento espectral más o menos alejado del anteriormente expuesto. La hoja senescente o enferma tiende a perder actividad clorofílica y, en consecuencia, a ofrecer una menor absortividad en las bandas azul y roja del espectro visible. El aumento consecuente de la reflectividad en estas bandas elimina el máximo relativo antes situado en el verde, por lo que la hoja tiende a mostrar un color amarillento. Por el contrario, en el infrarrojo cercano se produce una reducción de la reflectividad, como consecuencia de un deterioro en la estructura celular de la hoja. La curva espectral, por tanto, se hace más plana, menos cromática (Jackson *et al.*, 1986; Knipling, 1970; Murtha, 1978). Estas observaciones son válidas para detectar daños producidos por plagas o incendios forestales (Vogelman, 1990). Además, se ha comprobado que ciertos factores de estrés en la hoja están asociados a un desplazamiento en el límite del rojo *(red edge)* —esto es, en el cambio de pendiente de la curva espectral entre el rojo y el infrarrojo cercano—, hacia longitudes más cortas. Este fenómeno se ha observado, por ejemplo, cuando las plantas están afectadas por contaminación de metales pesados (Rock *et al.*, 1988; Westman *et al.*, 1988).

Por otro lado, en varios estudios se ha comprobado una clara relación entre el cociente IRC/SWIR y el contenido de humedad en las hojas, lo que permite determinar aquellas zonas afectadas por estrés hídrico (Ceccato *et al.*, 2001; Hunt y Rock, 1989).

5.3. El suelo en el espectro óptico

Como consecuencia del efecto de pantalla provocado por la cubierta vegetal no resulta sencillo obtener información del sustrato geológico a partir de sensores espaciales. Sin embargo, pueden obtenerse algunos datos indirectos sobre las características del suelo/litología gracias a las anomalías que puedan detectarse en esa cubierta

vegetal. Ejemplos de este tipo de modificaciones son: distribución peculiar de especies, crecimiento o densidad irregular, alteraciones de la pigmentación o del ciclo fenológico, etc. Si bien no todos estos fenómenos pueden ser imputados al sustrato geológico, algunos estudios han demostrado la posibilidad de inferir valiosa información de éste a partir de la vegetación (Lulla, 1985; Milton *et al.*, 1983). Esta técnica se ha bautizado con el nombre de geobotánica, demostrando gran interés para estudios regionales (Bruce y Hormsby, 1987).

En lo que atañe a los suelos desnudos, su comportamiento espectral es mucho más uniforme que el de la vegetación, mostrando una curva espectral más plana. Los principales factores que intervienen en este caso son la composición química del suelo, su textura, estructura y contenido de humedad (Labrandero, 1978).

La composición química es la causa del color dominante con el que percibimos el suelo (fig. 2.13). Los de origen calcáreo tienden al color blanco, indicando una alta reflectividad en todas las bandas visibles. Por su parte, los suelos arcillosos ofrecen una mayor reflectividad en el rojo, como consecuencia de su alto contenido en óxido de hierro. El contenido de humus resulta muy influyente en su color, tendiendo a una baja reflectividad, especialmente en torno a 0,70-0,75 μm (Curran *et al.*, 1990).

Respecto a las características físicas del suelo, puede afirmarse, en términos generales, que la reflectividad espectral resulta tanto mayor cuanto se trate de suelos más finos y apelmazados (Lusch, 1989).

El contenido de humedad es uno de los elementos más destacados en la reflectividad del suelo para estas longitudes de onda, como consecuencia de la alta absortividad del agua en estas bandas. Influye inversamente en la reflectividad del visible e infra-

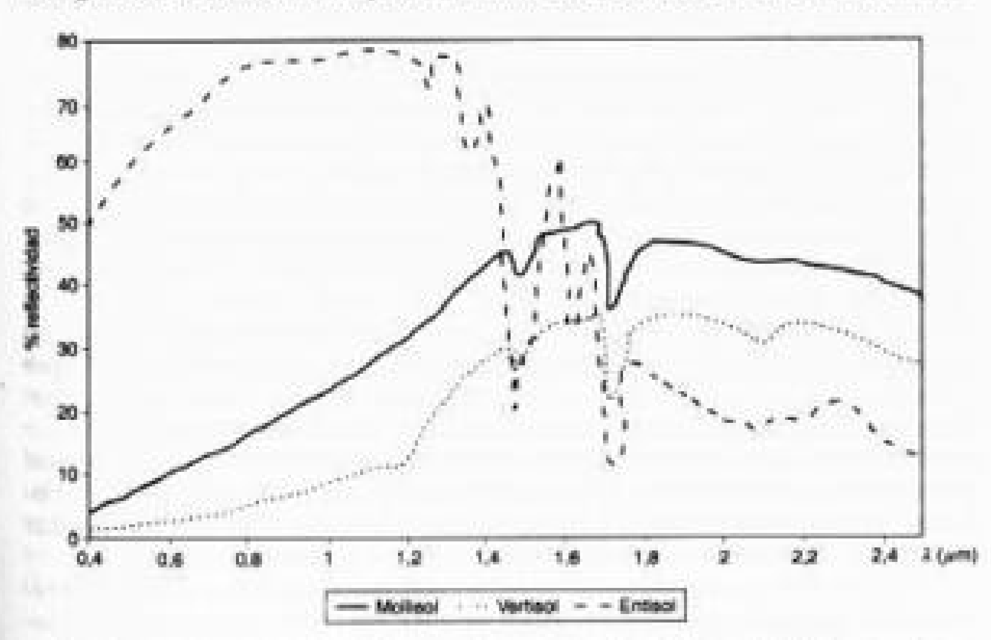


FIG. 2.13. *Curvas de reflectividad para distintos tipos de suelos: mollisol (limoso pardo-grisáceo); vertisol (arcilloso-marrón); entisol (yeso blanco).* Datos tomados de la librería espectral Aster.

rrojo, en torno a 1,45 μm y 1,92 μm, con mayor intensidad en las bandas de absorción del agua.

Como es bien sabido, textura, estructura y contenido de humedad están altamente relacionados. Por ejemplo, un suelo arcilloso tiende a retener mejor la humedad, lo que supone una baja reflectividad, pese a ser de fina textura. En contraste, un suelo arenoso tiende a tener una débil estructura y bajo contenido de humedad, por lo que presentará, en función de esos factores, una reflectividad más elevada (Curran, 1985). A ello convendría añadir el efecto de la materia orgánica en el suelo, que tiende a oscurecerle y, en consecuencia, a reducir su reflectividad.

5.4. El agua en el espectro óptico

Las superficies acuáticas absorben o transmiten la mayor parte de la radiación óptica que reciben, siendo mayor su absortividad cuanto mayor sea la longitud de onda. La curva espectral, por tanto, es similar a la del suelo, aunque de sentido contrario. La mayor reflectividad del agua clara se produce en el azul, reduciéndose paulatinamente hacia el infrarrojo cercano y medio, donde ya es prácticamente nula. Por esta razón, la frontera tierra-agua es muy nítida en esta banda.

La variabilidad del agua es más fácilmente detectable en las longitudes de onda más cortas (azul y verde), y se relaciona con su profundidad, contenido de materiales en suspensión (clorofila, sedimentos y nutrientes), y rugosidad de la superficie. La turbidez del agua, relacionada con su contenido de sedimentos, implica aumento de la reflectividad en todas las bandas del visible, para distintos diámetros de partícula (Bhargava y Mariam, 1990).

La profundidad del agua influye directamente en el aporte de reflectividad derivado de los materiales de los fondos. En aguas poco profundas la reflectividad aumenta, ya que se mezcla en el flujo recibido la reflectividad de los fondos. En consecuencia, la absortividad será tanto mayor cuanto más profunda sea la capa de agua. A partir de esta relación pueden abordarse algunos estudios de batimetría en zonas costeras. Para imágenes Landsat-TM se estima que la profundidad de agua máxima que puede determinarse alcanza 6,4 m en la banda azul, 3 en la verde y 2,1 en la roja (Ji *et al.*, 1992).

En cuanto a su composición, diversos estudios han demostrado la posibilidad de emplear sensores espaciales para cartografiar contenido de clorofila en el agua (López y Caselles, 1989). Si el agua ofrece importantes concentraciones de clorofila, la reflectividad en el azul tiende a descender, aumentando en el verde. Esto permite establecer una clara correlación, de signo negativo, entre la reflectividad del agua en la banda azul y el contenido de clorofila, lo que facilita localizar concentraciones de algas (Robinson, 1985), analizar ritmos de productividad neta de la superficie marina o estudiar procesos de eutrofización en embalses (Ruiz-Verdú *et al.*, 2001; Verdin, 1985).

El resto de los materiales en suspensión contribuyen también a aumentar la reflectividad, además de presentar una mayor turbidez. Por último, la rugosidad de la superficie favorece la reflexión difusa, y en consecuencia una mayor reflectividad. En caso de aguas muy tranquilas, la superficie se comporta de modo especular, con valores de reflectividad muy variados en función de la localización del sensor. En el caso

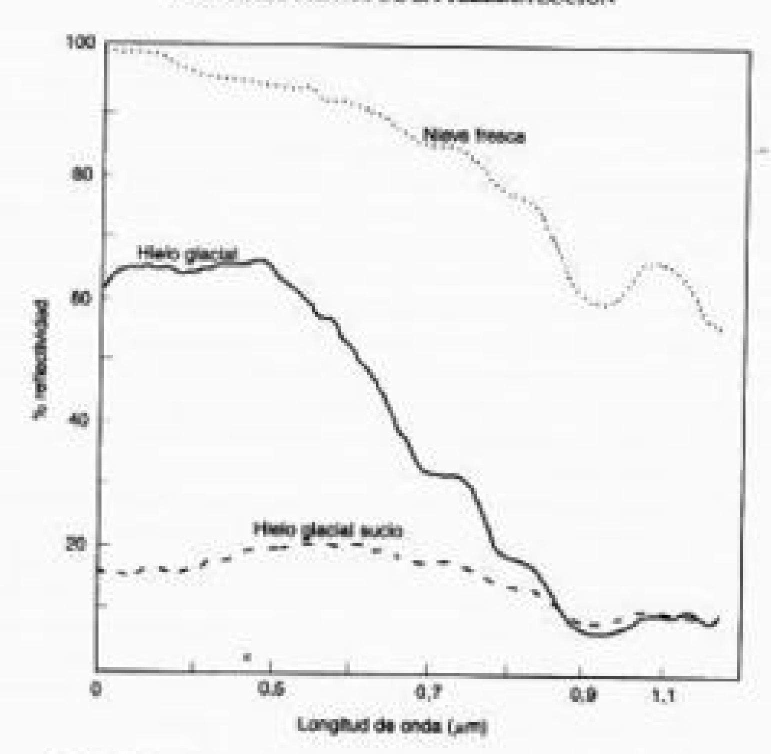


Fig. 2.14. *Curvas de reflectividad para distintos tipos de nieve.* (Adaptado de Hall y Martinec, 1985.)

de las medidas tomadas con sensores espaciales, los valores resultan extremadamente bajos.

La nieve, por su parte, ofrece un comportamiento muy distante del agua. Presenta una reflectividad elevada en las bandas visibles, reduciéndose en el infrarrojo cercano y más claramente en el medio. Los factores más destacados en la reflectividad de la nieve son el tamaño del grano, la profundidad y densidad de la capa y la cantidad de impurezas que contenga (Dozier, 1989). La reflectividad es mayor para la nieve fresca que para la helada, mostrando los valores más bajos la nieve sucia (fig. 2.14). La reducción puede llegar hasta el 80 % para las bandas visibles (Hall, 1988; Hall y Martinec, 1985).

A veces no resulta sencillo distinguir la nieve de las nubes en el espectro visible. La distinción resulta más evidente en el infrarrojo medio, ya que las gotas o cristales de hielo de las nubes son más pequeñas que los granos de nieve, por lo que absorben menos radiación en esta banda del espectro. Además, habitualmente, la nieve tiene mayor reflectividad que las nubes en el visible y una textura más homogénea (Dozier, 1989).

5.5. Bibliotecas espectrales

El creciente desarrollo que en los últimos años están teniendo los sensores de muy alta resolución espectral (que permiten registrar simultáneamente la reflectividad en un gran número de bandas: cap. 3, apdo. 5.10.2), ha estimulado la creación de bibliotecas espectrales. Se trata de colecciones de espectros, habitualmente tomados en laboratorio, bajo condiciones controladas, que intentan recoger la reflectividad característica de una amplia variedad de materiales terrestres.

Estas bibliotecas se están utilizando para calibrar los valores de reflectividad estimados a partir de la imagen, facilitar el entrenamiento automático en la interpretación de cubiertas y servir como entrada para la extracción de modelos de mezclas espectrales (cap. 7, apdo. 1.6.1).

Aunque todavía son escasas las bibliotecas espectrales disponibles, conviene citar la desarrollada por el Servicio Geológico Estadounidense (USGS: Clark *et al.*, 1993), accesible a través de Internet (http://speclab.cr.usgs.gov), que cuenta con una amplia variedad de espectros, aunque son muy escasos los correspondientes a cubiertas vegetales. Esta biblioteca está bien documentada y cubre el rango de 0,2 a 3 μm.

Algo más reciente es la biblioteca espectral compilada por el *Jet Propulsión Laboratory* (JPL), denominada ASTER (http://speclib.jpl.nasa.gov) con casi 2.000 curvas espectrales situadas entre 0,4 y 2,5 μm, aunque para muchas de ellas se ofrece información hasta el infrarrojo térmico (15 μm). Este proyecto parte de la biblioteca compilada por el USGS, la Universidad Johns Hopkins y el propio JPL. Incluye espectros de minerales, rocas, suelos, meteoritos, vegetación (solamente 4 especies), agua, nieve y cubiertas humanas (asfalto, cemento, aluminio, cobre, papel, diversos tipos de pinturas, etc.). Para cada espectro se incluye un archivo de documentación, que facilita datos sustanciales sobre la fuente y condiciones de adquisición y el tipo de material observado (incluyendo tamaño de las partículas y composición química), si bien los espectros, al provenir de fuentes diversas, se tomaron con diferentes criterios y no son completamente comparables.

Menos conocida, pero también de gran interés, es la biblioteca espectral disponible en la Universidad de Purdue (http://shay.ench.purdue.edu/~frdata/FRDATA/Index.html), uno de los centros pioneros en aplicaciones agrícolas de la teledetección. Incluye una amplia variedad de espectros referidos a cultivos y suelos, principalmente. Estos datos fueron tomados a lo largo de una serie de 18 años, por distintos espectro-radiómetros, tanto terrestres como aéreos. Cada archivo está documentado adecuadamente, describiendo las variables fisiológicas medidas en campo junto a los ángulos de observación e iluminación.

Uno de los pocos casos conocidos de bibliotecas espectrales exhaustivas es el llevado a cabo por Dar Roberts, de la Universidad de California (Santa Bárbara). En él se han recogido reflectividades de todas las especies del ecosistema de chaparral californiano (Roberts *et al.*, 1998), con objeto de hacer una clasificación de coberturas vegetales para la cartografía y estudio de combustibles de cara a estimar peligros de incendios.

En el ámbito europeo probablemente la mejor estructurada es la obtenida en el marco del proyecto europeo STORMS: *Silvicultural Techniques Offering Risk Minimising Strategies* (Caetano y Oliveira, 1998), desarrollada en Portugal y centrada en

mediciones de todas las superficies y cubiertas que puedan tener alguna influencia en el riesgo de incendios forestales. Esta biblioteca incluye dos tipos de archivos, los correspondientes a las bandas del sensor Landsat *Thematic Mapper* (TM) y un espectro continuo de 512 bandas situadas entre 0,35 y 1,05 μm.

6. El dominio del infrarrojo térmico

6.1. Características de la radiación energética en el infrarrojo térmico

De acuerdo con las leyes de Planck [2.4] y Wien [2.6], podemos fijar entre 8 y 14 μm la banda espectral en donde se manifiesta con mayor claridad la emitancia espectral de la superficie terrestre, de acuerdo a su temperatura (unos 300 K). A esta parte del espectro se le denomina infrarrojo térmico, puesto que nos permite detectar el calor que procede de las distintas cubiertas. En definitiva, para esta banda la radiancia espectral que recibe el sensor no es el resultado de la reflexión de la energía solar sobre la superficie terrestre, sino de la radiación emitida por ésta.

Como vimos, la emitancia espectral de un objeto está directamente relacionada con su temperatura absoluta. A la vez, ésta se relaciona con su capacidad para absorber la radiación solar incidente. De la fórmula [2.11] se deduce que ésta puede ser reflejada, absorbida o transmitida. Considerando que la transmisividad es prácticamente nula en el infrarrojo térmico, la expresión puede simplificarse indicando que, a estas longitudes de onda, la energía incidente, o bien se refleja o bien se absorbe. Junto a ello es preciso tener en cuenta que cuando una superficie está en equilibrio térmico con los alrededores, la ley de Kirchoff indica que la absortividad espectral es igual a la emisividad. En otras palabras, a mayor absorción, mayor emisión, por lo que podemos expresar la fórmula [2.11] indicando:

$$1 = \rho_{\lambda,n} + \varepsilon_{\lambda,n} \qquad [2.13]$$

lo que, en resumen, significa que las superficies con alta reflectividad (caso de la nieve) son poco emisivas, mientras las poco reflectivas son altamente emisivas (como ocurre con el agua).

Como ya vimos anteriormente, la emisividad de un tipo de cubierta es una medida relativa, que pone en relación su emitancia con la de un cuerpo negro. Una alta emisividad (cercana a 1) indica que un objeto absorbe y radia una gran proporción de la energía incidente, mientras una emisividad considerablemente inferior a 1 refiere a un objeto que absorbe y radia una pequeña proporción de la energía incidente. En el caso de las cubiertas de interés medioambiental, la mayor emisividad se presenta en la vegetación densa (0,99) y el agua (0,98), mientras los valores más bajos corresponden a los suelos arenosos (0,90), nieve (0,80) y metales (0,16). Varios autores han llevado a cabo mediciones sistemáticas de la emisividad en terreno, tanto en el IRT como en el IRM (3-5 μm) (Salisbury y D'aria, 1992; Salisbury y D'aria, 1994).

El contenido de humedad modifica notablemente estos valores estándar. Así, en suelos arenosos se han medido incrementos de emisividad de 0,90 a 0,94 al aumentar

un 8 % el contenido de humedad (Mulders, 1987). Los valores de emisividad se calculan para una temperatura media, en este caso en torno a 20 °C (Curran, 1985).

A partir de la medida de la emisividad puede estimarse la emitancia global de un objeto, conociendo su temperatura. En este sentido puede corregirse la ley de Stefan-Boltzmann, introduciendo el parámetro de emisividad:

$$M_n = \varepsilon\, \sigma\, T_4 \qquad [2.14]$$

Esto implica que dos objetos situados a la misma temperatura pueden presentar emitancias radiantes distintas. De esta forma, parece evidente la necesidad de corregir los valores de radiancia adquiridos por el sensor considerando la emisividad, que puede estimarse siempre y cuando se conozca la cubierta detectada y ésta sea suficientemente homogénea. En caso de un área con cubiertas muy distintas, cada una de ellas con su propia emisividad, el problema sería mucho más complejo. Habría de hacerse una corrección en función de las coberturas presentes en esa zona, conociendo la emisividad propia de cada una de ellas. En ocasiones se ha utilizado un mapa de ocupación del suelo previo para facilitar la corrección de emisividades (Caselles *et al.*, 1988), aunque también puede basarse en una correlación de radiancias-temperaturas con medidas tomadas en el terreno o en estaciones meteorológicas (Sobrino, 2000, cap. 11). Recientes trabajos han mostrado que, en cubiertas vegetales suficientemente densas, basta incorporar la emisividad de ésta y no la del suelo que la soporta, lo cual simplifica notablemente los cálculos. Más adelante veremos con detalle los procedimientos para proceder al cálculo de la temperatura a partir de imágenes adquiridas en esta región del espectro (cap. 6, apdo. 6.2).

Además de la emisividad, el comportamiento térmico de un objeto está relacionado con otros parámetros. Los más importantes son su capacidad térmica, conductividad, difusividad, inercia térmica e índice de calentamiento.

La capacidad térmica (*C*) indica la capacidad de la cubierta para almacenar calor. La capacidad térmica por unidad de masa se denomina calor específico (*c*). Las masas de agua poseen la mayor capacidad térmica, por lo que pueden almacenar más calor que la vegetación o los suelos.

La conductividad térmica (*k*) mide el ritmo al que se transmite el calor en esa cubierta. Las áreas urbanas son buenas conductoras de calor, mientras la vegetación o suelos resisten más esta transferencia. Por ello, la temperatura diurna en zonas de cubierta vegetal es fundamentalmente una función de la temperatura de la capa superior, y no de capas inferiores.

La difusividad térmica (*a*) es una medida del cambio de temperatura que se produce en el interior de la cubierta. En general, las superficies secas difunden los cambios de temperatura hacia abajo a una velocidad menor que las superficies húmedas.

Por último, la inercia térmica (*P*) hace referencia a la resistencia de un material a cambiar de temperatura. Este parámetro está directamente relacionado con la conductividad (*k*), el calor específico (*c*) y la densidad del material (*D*), de acuerdo a la siguiente fórmula:

$$P = \sqrt{Dck} \qquad [2.15]$$

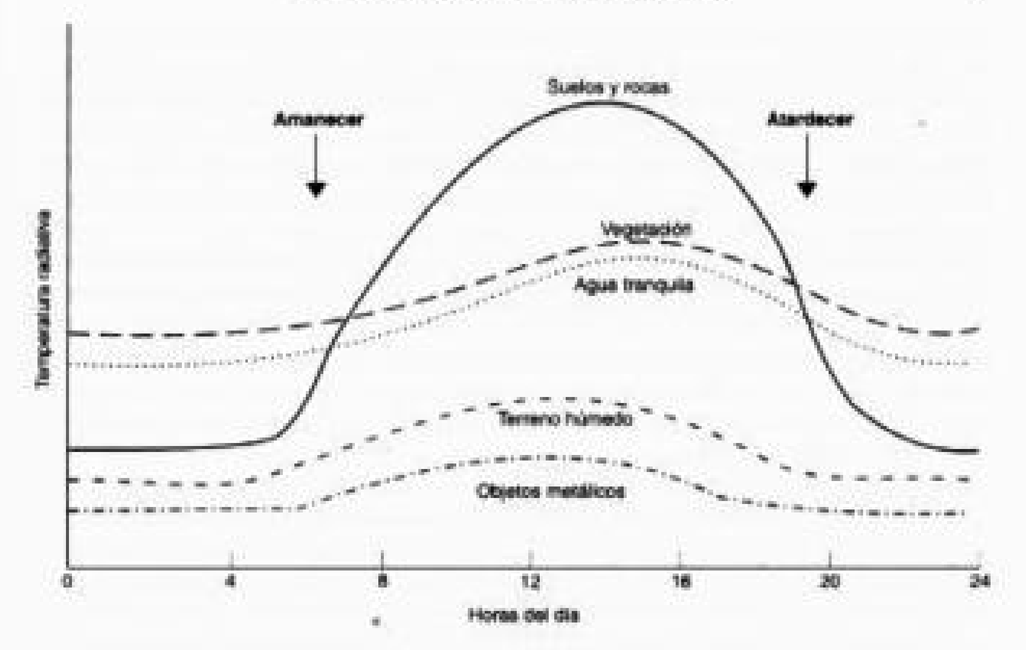


FIG. 2.15. *Inercia térmica estimada para diversas cubiertas.* (Adaptado de Short, 1982.)

Los suelos secos y arenosos, con baja inercia térmica, ofrecen severos contrastes entre las temperaturas diurnas y nocturnas. En contraste, los suelos húmedos y arcillosos son mucho más resistentes al cambio y presentarán temperaturas diurnas inferiores y nocturnas superiores a los suelos secos (fig. 2.15). La inercia térmica es más fácilmente detectable en los momentos de máxima y mínima insolación, aproximadamente a las 12 y 24 h respectivamente.

En cuanto al índice de calentamiento, es función de la intensidad de la radiación y de la absortividad del objeto. La intensidad es menor en aquellas zonas arboladas, con nubes o con edificios que impidan la radiación directa. También está afectado directamente por la pendiente o exposición de las laderas.

6.2. COMPORTAMIENTO ESPECTRAL DE LA VEGETACIÓN EN EL INFRARROJO TÉRMICO

Las propiedades térmicas de la vegetación son bastante complejas, puesto que absorbe una gran cantidad de la energía solar que recibe para realizar la función clorofílica. Esta energía es re-emitida durante la noche para mantener el balance energético.

En consecuencia, la vegetación posee una alta inercia térmica, que se subraya por el elevado contenido de agua que suelen disponer las hojas (habitualmente entre un 80 y un 400 % de su peso seco, según las especies). Esta variable supone un elemento básico para la vida de las plantas, por lo que la regulación hídrica es uno de los procesos fisiológicos más importantes en la vegetación. El aumento de la temperatu-

ra ambiente (como consecuencia de la mayor radiación) implica un aumento de la transpiración de las hojas, siempre que se encuentren bien drenadas. La energía liberada como flujo de calor latente disminuye el calor sensible de las plantas, lo que explica que tiendan a estar más frías durante el día que su entorno. Este proceso se revierte durante la noche, cuando se re-emite la energía recogida de día, a la longitud de onda del térmico, lo que explica que ofrezca una mayor temperatura que las áreas limítrofes.

Este mecanismo de regulación térmica de la vegetación permite analizar su estado hídrico a partir de la información registrada en el infrarrojo térmico. Las estimaciones de evapotranspiración (*ET*) en cultivos o vegetación natural se han llevado a cabo a partir de la ecuación del balance de energía:

$$Rn = \xi ET + H + G + PH \qquad [2.16]$$

donde: R_n es la radiación neta; λET es el flujo de calor latente o evapotranspiración donde ξ es el calor latente de vaporización y *ET* el flujo de agua evaporada; *H* es el flujo de calor sensible; *G* es el flujo de calor del suelo; *PH* es la energía utilizada en la fotosíntesis y en calentar la biomasa vegetal (Sánchez, 1992). De los procesos incluidos en la ecuación, sólo la *Rn* puede obtenerse en forma relativamente directa a partir de medidas de satélite (López-Baeza, 1991), los demás términos se pueden obtener combinando con información observada en tierra. En Desbois *et al.* (1997) se presenta la solución a cada uno de los términos apoyada en información proporcionada por teledetección. Otros autores proponen fórmulas alternativas, basadas también en la diferencia entre temperatura del aire (medida habitualmente a partir de estaciones meteorológicas) y temperatura del suelo (estimada por teledetección). Los resultados para estimar *ET* instantánea pueden considerarse bastante prometedores, tanto a escala regional (Margaritz *et al.*, 1990) como global (Choudhury, 1997). También se han propuesto varios métodos para mejorar la interpolación espacial de la *ET* utilizando imágenes de satélite (Sánchez y Chuvieco, 2000).

Por último conviene recordar que las variaciones de *ET* están relacionadas, por un lado, con la propia fisiología de la planta, principalmente con su capacidad de retención de agua y geometría de las hojas (resistencia estomatal y resistencia aerodinámica). También es preciso considerar otros factores atmosféricos externos, como la humedad atmosférica, velocidad del viento, disponibilidad de luz, temperatura del aire y humedad del suelo. La humedad atmosférica reduce la evapotranspiración, mientras el resto de los factores la aumentan.

Otro elemento importante que afecta a la emisividad de la vegetación es su extensión y densidad. Las grandes superficies verdes producen una elevada radiación, que puede ser incluso 30 veces superior a la correspondiente a los suelos vecinos (Curran, 1985).

6.3. Los suelos y el agua en el dominio térmico

Respecto a los suelos, el contenido de humedad es el factor más destacado de su conducta térmica. A mayor humedad, el suelo presentará una mayor inercia térmica,

puesto que aumenta su calor específico y conductividad. Esto le lleva a presentarse más frío durante el día y más cálido durante la noche que los suelos secos.

Otros parámetros a considerar serían la densidad, calor específico y conductividad del tipo de material que forma el suelo. Diversos estudios de laboratorio han mostrado cómo el cuarzo presenta una densidad y calor específico similar a la arcilla, pero ofrece valores de conductividad mucho más elevados. Por ello, su inercia térmica es mayor, a la vez que cuenta con bajos valores de emisividad (0,90). Los suelos con alto contenido de materia orgánica ofrecen los valores más bajos de conductividad, por lo que tienden a mostrar más nítidamente las diferencias de temperatura entre el día y la noche.

De los párrafos anteriores se deduce fácilmente que el agua posee la mayor inercia térmica. Esta resistencia a cambiar de temperatura es debida a su alta conductividad: la radiación incidente es fuertemente absorbida y transmitida a lo largo de la superficie por movimientos de convección, con lo que resulta más difícil que cambie de temperatura. Esto permite detectar con bastante facilidad plumas de agua provenientes de fuentes ajenas al entorno, como sería agua con materiales en suspensión o descargas de centrales nucleares. Asimismo, cartografiar la temperatura de la superficie marina resulta de gran interés para la detección de bancos de pesca (Cañón, 2000; Tameishi, 1991) o el estudio global del clima, tanto en lo que se refiere a tendencias promedio (calentamiento de algunas zonas), como a movimientos particulares de las corrientes oceánicas. Por ejemplo, la detección precoz del fenómeno de El Niño, que provoca efectos de escala planetaria, se realiza a partir de sensores térmicos, ya que obedece a un calentamiento inusual de una enorme masa de agua situada sobre el Pacífico Sur.[3]

Volviendo a las propiedades térmicas de las cubiertas terrestres, la temperatura de la nieve está influida por el tamaño de los cristales y el contenido de agua líquida, siendo en líneas generales muy baja. Como ya vimos, esta cubierta ofrece la mayor reflectividad en el visible, por lo que la absorción de energía es baja y tiende a registrar más bajas temperaturas que el entorno. La observación de la nieve en el térmico es de gran ayuda para diferenciar tipos y estudiar la dinámica de su cobertura, de cara a estimar volumen de agua almacenada (Ferris y Congalton, 1989).

7. La región de las micro-ondas

7.1. Características de la radiación energética en la región de las micro-ondas

La banda del espectro que se inicia en las longitudes de onda milimétricas se denomina región de las micro-ondas. Se trata de las longitudes mayores utilizadas en teledetección, si bien cuentan asimismo con otras aplicaciones civiles y militares.

3. Son muy numerosas las referencias en Internet que pueden consultarse sobre este fenómeno. Específicamente en lo que se refiere a su observación mediante imágenes de satélite, resultan de interés las de NOAA (www.pmel.noaa.gov/tao/elnino/nino-home.html) y NASA (airsea-www.jpl.nasa.gov/ENSO/intro.html).

La observación en esta banda del espectro es complementaria y más compleja que la realizada en las bandas ópticas o térmicas, por lo que el rango de aplicaciones es todavía inferior al registrado en éstas, si bien está aumentando notablemente en los últimos años, gracias a la creciente disponibilidad de satélites equipados con equipos de micro-ondas (ERS, Radarsat, JERS, Almaz, etc.). La virtud fundamental de esta región del espectro es ser prácticamente transparente a la influencia atmosférica, ya que se trabaja a longitudes de onda muy superiores al tamaño habitual de las gotas de agua (0,1 mm: fig. 2.16). Esta propiedad hace idóneo el trabajo en esta región del espectro, especialmente para recoger información de aquellas zonas del planeta donde la cubierta de nubes es muy frecuente, como ocurre en las zonas tropicales o polares. Por ejemplo, el radar lateral aero-transportado (SLAR) permitió completar la primera cartografía de la cuenca del Amazonas y de varios países de Centroamérica, detectando recursos hídricos y mineros antes desconocidos (Henderson y Lewis, 1998).

La observación remota en esta banda se realiza habitualmente con sensores activos (denominados en esta banda, radar), que no se limitan a registrar la radiación emitida por las cubiertas, sino que emiten la suya propia, recogiendo posteriormente su retro-dispersión. Esto permite una gran versatilidad a la teledetección de microondas, ya que pueden observarse las cubiertas con las condiciones específicas que parezcan más convenientes para una determina aplicación.

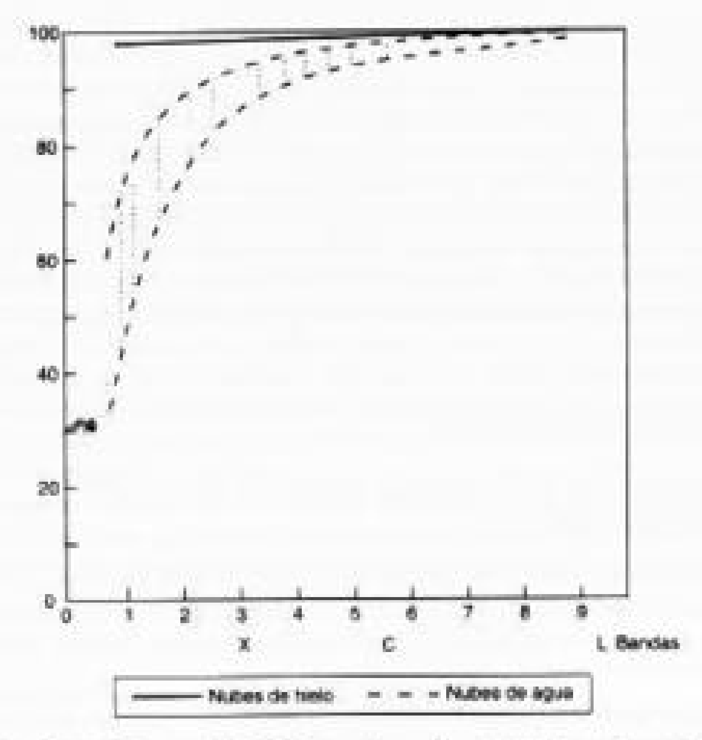


FIG. 2.16. *Transmisividad de las nubes en la región de las microondas.* (Adaptado de ESA, 1995.)

Los sensores pasivos en esta banda se denominan radiómetros de micro-ondas. Son poco utilizados en teledetección, puesto que la emitancia de los objetos es difícilmente perceptible en esta banda. Para las longitudes de onda que comprende se emplea la aproximación de la ley de Planck calculada por Rayleigh-Jeans (Elachi, 1987):

$$M_{n,\lambda} = \frac{2\pi kT}{\lambda^4} \qquad [2.17]$$

donde $M_{n,\lambda}$ corresponde a la emitancia espectral, T a la temperatura en Kelvin, y λ a la longitud de onda. Las constantes tienen el mismo significado que en [2.4]. En esta región, los valores de M_λ son muy bajos, y existen frecuentes interferencias entre señales emitidas, reflejadas y transmitidas. Por ello, no es una técnica muy difundida en teledetección espacial, aunque se ha mostrado de gran interés para el estudio de capas de hielo y nieve. La cartografía de la Antártida a partir del radiómetro ESMR del satélite Nimbus-5 (Hall y Martinec, 1985, pp. 141-149) resulta muy significativa a este respecto. Otros autores han propuesto estimar el grosor de la cobertura de nieve a partir de las diferencias de temperaturas entre dos canales de micro-ondas detectados por el mismo sensor (Chang *et al.*, 1990). En el campo de los suelos o la vegetación se ha propuesto el empleo de estos equipos para determinar el contenido de humedad (Paloscia, 1994), aunque su limitación más importante sigue siendo la baja resolución espacial que ofrecen desde plataformas especiales.

Pese al interés de estas experiencias, el radar es el sensor más importante en esta banda del espectro. Este acrónimo indica que se diseñó inicialmente para medir distancias y detectar objetos en movimiento (Radar, *Radio Detection and Ranging*), si bien se han adaptado diversas configuraciones para obtener imágenes bidimensionales de los pulsos de retorno. Por tratarse de un haz emitido artificialmente, pueden controlarse las condiciones de adquisición: ángulo, distancia, orientación, polarización, etc. Esto facilita la interpretación posterior de la señal, si bien es una tarea compleja ante la gran cantidad de factores que intervienen en el proceso.

Al igual que en la observación en el espectro óptico, en esta región también podemos distinguir una serie de bandas de características comunes. Siguiendo una terminología extraída, en buena parte, de las aplicaciones militares que dieron origen al radar, las bandas de micro-ondas se denominan por una letra, y suelen acotarse por rangos de frecuencia (normalmente GHz: tabla 2.2).

Cuando se emite un haz de micro-ondas desde un radar a la superficie terrestre, la mayor parte de ese haz es dispersado al contacto con ella. Según la naturaleza del sustrato, el haz principalmente se dispersa al exterior (caso del suelo), se dispersa dentro del propio objeto (caso de la vegetación), o se refleja especularmente (caso del agua). En función de estos tres comportamientos el radar registrará una señal de retorno muy distinta (fig. 2.17).

Desgraciadamente, como ocurre en otras bandas del espectro, tampoco aquí cada cubierta ofrece un comportamiento único y constante. Otros factores, que podríamos denominar medio ambientales, influyen en la señal finalmente detectada por el sensor. Entre ellos, los más importantes son la rugosidad y geometría del terreno, el ángulo de

TABLA 2.2. *Bandas de frecuencia habitualmente utilizadas en micro-ondas*

Denominación	*Anchura (cm)*		*Valor típico*	*Anchura (GHz)*	
Ka	0,75	1,10			
K	1,10	1,67	1,0	10,9	36
Ku	1,67	2,40			
X	2,40	3,75	3,0	5,75	10,90
C	3,75	7,50	5,6	3,90	5,75
S	7,50	15,00	10,0	1,55	3,90
L	15,00	30,00	23,0	0,39	1,55
P	30,00	100,00		> 0,39	

incidencia del flujo y su polarización. Estos factores introducen una cierta variabilidad en torno al coeficiente promedio de cada tipo de cubierta, principalmente afectado por su conductividad o constante dieléctrica. Con estos elementos podemos abordar la ecuación fundamental del radar:

$$P_r = \frac{P_t G^2 \lambda^2 \sigma}{(4\pi)^3 r^4} \qquad [2.18]$$

donde P_r, indica la potencia retro-dispersada; P_t, la potencia emitida por el radar, G es un factor de ganancia de la antena; r, indica la distancia entre el sensor y la cubierta, y σ la sección eficaz de retro-dispersión.

Precisamente este último factor, σ, es el que implica una mayor complejidad, puesto que depende de diversos factores. Entre los más importantes se cuentan la rugo-

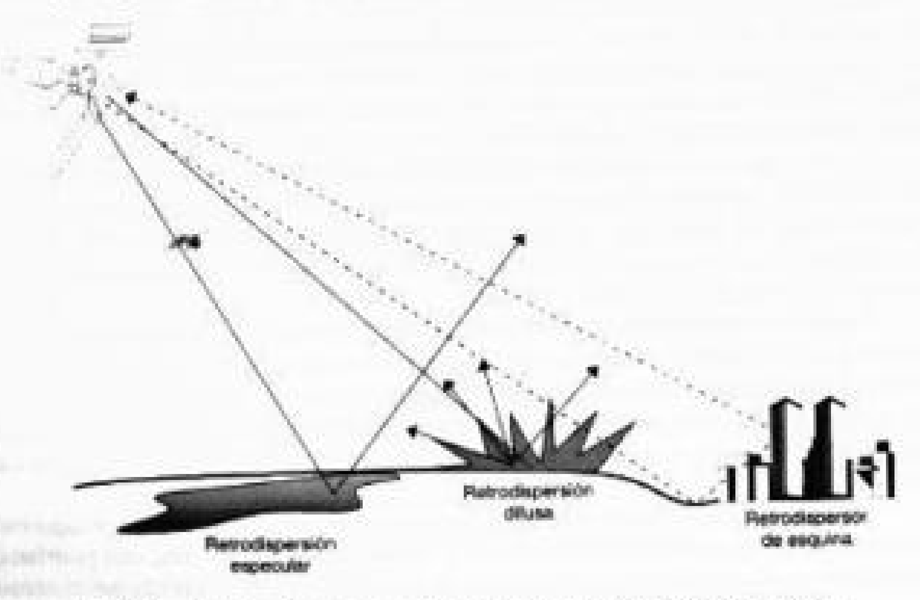


FIG. 2.17. *Distintos tipos de retrodispersión.* (Adaptado de Campbell, 1987.)

sidad del material y sus condiciones dieléctricas y las condiciones del terreno, principalmente pendiente y orientación frente al flujo emitido.

En cuanto a la rugosidad, parece comprobado que incide directamente en la intensidad de la señal de retorno, siendo ésta mayor cuando más elevada es la rugosidad. Conviene recordar, sin embargo, que el concepto de rugosidad no sólo depende de la estructura de la superficie, sino también de la longitud de onda de la observación. En longitudes cortas una superficie relativamente llana puede aparecer como rugosa, mientras se comporta como lisa en longitudes mayores (fig. 2.18). Esta relación se concreta gracias al criterio de Rayleigh, que considera una cubierta como rugosa si:

$$s_h \geq \frac{\lambda}{8} \cos \theta \qquad [2.19]$$

donde s_h es la desviación típica de la altura de la superficie; λ la longitud de onda de observación, y θ el ángulo de incidencia. En pocas palabras, esto indica que a igual rugosidad del terreno, éste aparecerá tanto más liso cuanto se trabaje a longitudes de onda mayores, y/o con ángulos de incidencia mayores (esto es, en una observación más oblicua). Esta relación es muy importante, ya que en una superficie que aparece como rugosa, la dispersión de retorno se dirige en todas las direcciones y el sensor capta una fuerte señal. En cambio, si la cubierta aparece lisa la reflexión tiende a ser especular y la señal de retorno puede llegar a ser prácticamente nula. Éste es el caso de las masas de agua en calma, que aparecen con tonos oscuros en una imagen radar (fig. 2.19).

Por otra parte, las características eléctricas de la cubierta juegan un papel tan destacado como la geometría de observación en la señal retornada al sensor. Una de las medidas de este comportamiento es la denominada constante dieléctrica compleja, que intenta medir la conductividad y reflectividad de un tipo de material. En términos generales, los materiales secos ofrecen una constante dieléctrica entre 3 y 8, mientras el agua ofrece un valor de 80. En consecuencia, la presencia de agua en el suelo o la vegetación puede alterar significativamente el pulso de retorno. Por esa razón, la vegetación —casi siempre cargada de humedad— tiende a ofrecer un pulso de retorno mayor que los suelos secos. También son buenos conductores las superficies metálicas, que ofrecen valores de retro-dispersión bastante elevados.

Junto a la rugosidad, conviene asimismo considerar la geometría del terreno: pendientes y orientaciones al ángulo de incidencia del radar. En el caso de zonas urbanas resulta muy frecuente obtener señales de retorno particularmente intensas, debido a la presencia de los denominados reflectores de esquina, que cambian la trayectoria de la señal incidente retornándola en la misma dirección de origen.

También resulta muy destacado el efecto del ángulo de incidencia sobre el coeficiente de retro-dispersión. Como ya hemos dicho, a mayor ángulo, en general menor pulso de retorno, puesto que la rugosidad y, en consecuencia, la dispersión, es menor. Además, si se combina un ángulo de incidencia bajo con una longitud de onda larga, el pulso del radar puede penetrar a una cierta profundidad, consiguiéndose interesante información sobre fondos de vegetación o suelos. Conviene tener en cuenta que el ángulo de incidencia cambia en la dirección perpendicular a la trayectoria del avión o satélite;

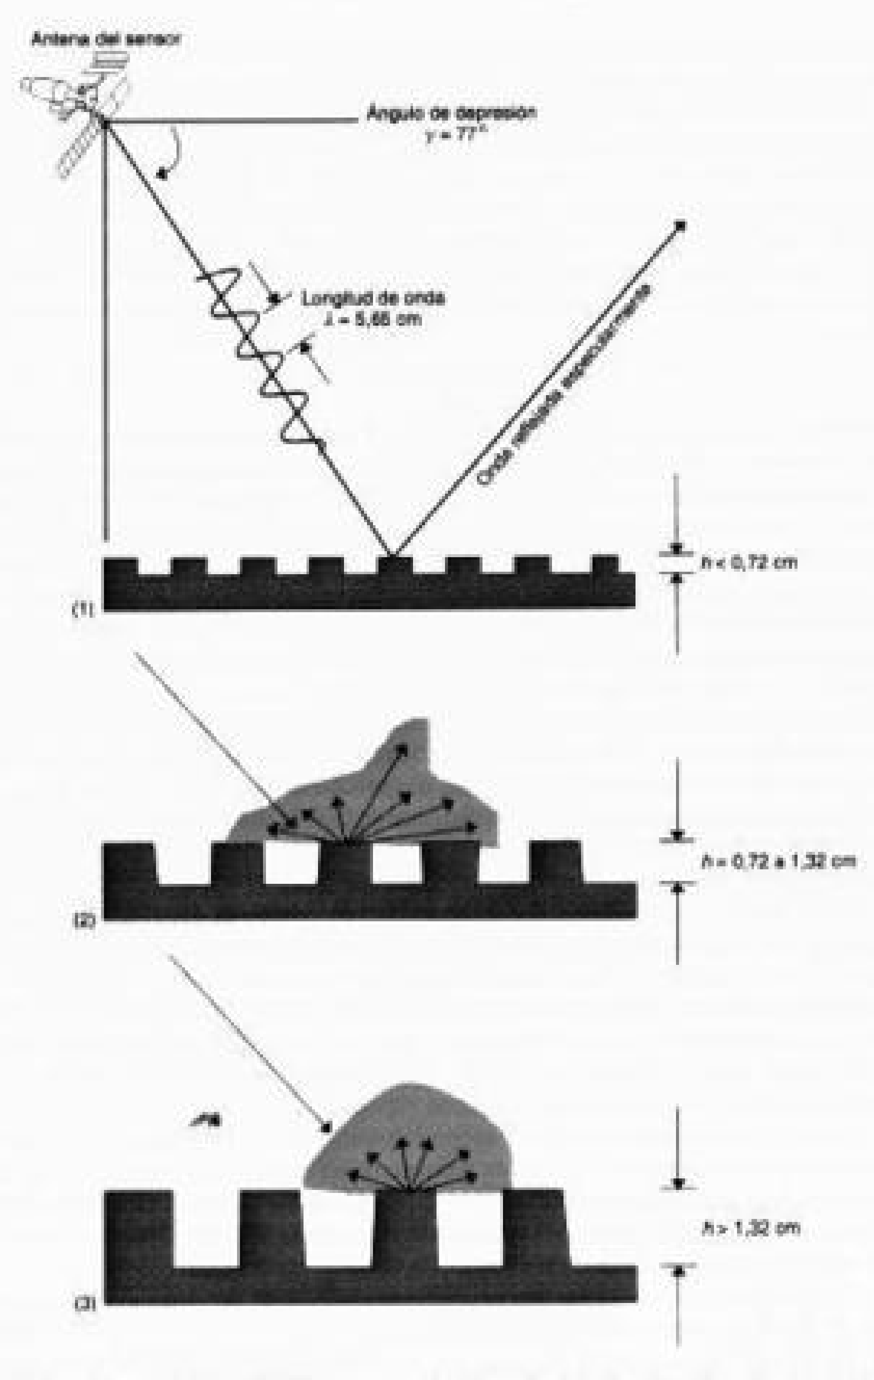


FIG. 2.18. *La retro-dispersión del terreno está en función de la longitud de onda y la variación altitudinal de la cubierta: (1) superficie suave, nula señal de retorno; (2) superficie moderadamente rugosa, retorno medio; (3) superficie rugosa, retorno intenso.* (Adaptado de Lillesand y Kiefer, 1994.)



FIG. 2.19. *Imagen adquirida por el radar del satélite europeo ERS sobre el río Mississippi afectado por severas inundaciones (julio de 1993).* (Cortesía: ESA.)

en definitiva, no es constante para cada punto de la imagen, ya que la observación que realizan los equipos radar es lateral, como veremos en el capítulo 3. También del ángulo de incidencia depende la información morfológica que proporciona el radar. Con ángulos altos, el efecto de sombra se realza notablemente, aunque también lo hacen las deformaciones geométricas. Esta sombra es relativa a la orientación de la topografía frente a la antena, de ahí que si se varía el ángulo de incidencia pueden conseguirse efectos estereoscópicos. A partir de esa reconstrucción tri-dimensional se realza notablemente el estudio de la geología y geomorfología local (ver, más adelante, la fig. 3.29).

Por último, la polarización refiere al tipo de vibración con la que son transmitidas y recibidas las señales del radar. Una señal polarizada indica que su vibración se restringe a una dirección determinada. Las dos formas más importantes son la polarización semejante, cuando la señal emitida y la recibida tienen la misma polarización

(Horizontal-Horizontal o Vertical-Vertical), y la cruzada, cuando varía la polarización entre la señal emitida y la recibida (Horizontal-Vertical o Vertical-Horizontal). La dirección con que la señal está polarizada influye en el flujo de retorno, puesto que el eco del radar es selectivo a la dirección de propagación.

7.2. Características de la vegetación en la región de las micro-ondas

En lo que afecta a la vegetación, la rugosidad es un elemento fundamental en la señal de retorno. La rugosidad es muy dependiente del tamaño, forma, orientación y número de hojas. A partir de la observación en una sola banda resulta, en consecuencia, muy complicado distinguir tipos de vegetación. En varios proyectos de inventario forestal se ha puesto en evidencia la dificultad para separar, por ejemplo, coníferas de caducifolias, tanto en banda L (Deane, 1980), como en banda S, X y C, como consecuencia de la gran variabilidad de coeficientes de retro-dispersión en coníferas (Hyyppa y Hallikainen, 1996; Leckie, 1990).

Respecto a la conductividad, la constante dieléctrica es bastante alta y constante para la mayor parte de las masas vegetales, incrementándose con el mayor contenido de humedad durante la época de crecimiento. Cuando la vegetación pierde vigor o el aporte del suelo es mayor, la constante dieléctrica disminuye drásticamente. De aquí se deduce que es posible obtener información sobre la humedad del sustrato vegetal, siempre y cuando se trabaje con ángulos de incidencia altos (Paloscia, 1994).

En una experiencia piloto para medir la humedad de una superficie de praderas se observaron mejores ajustes trabajando en bandas cortas (banda X), y con ángulos de incidencia de 30°, con los que se logró un coeficiente de determinación (r^2) del 90 %. Para ángulos más bajos, hasta de 0°, sólo se consiguieron ajustes del 50 %. Un efecto similar, aunque con peores correlaciones, se observó en la banda C (Gogineni *et al.*, 1991).

La profundidad de penetración en masas vegetales es dependiente de la longitud de onda a la que se trabaje, así como de las condiciones de humedad del sustrato y de la polarización. Resulta mayor a longitudes largas (banda L, en donde influyen notablemente las condiciones del sustrato), y con señales de polarización semejante (HH o VV), mientras se reduce a longitudes cortas (banda X, más sensible a la geometría y orientación de las hojas) o con señales de polarización cruzada (HV o VH). De acuerdo a algunos autores, en la banda X puede estimarse la rugosidad de la vegetación, en la C la biomasa de la hoja y en la L la biomasa de la madera (Curran y Foody, 1994*b*; Dobson, 2000). Hasta ahora, la mayor parte de las misiones espaciales sólo disponían de una banda radar (caso del ERS o del Radarsat), por lo que no ha resultado posible aplicar algunas técnicas de interpretación multifrecuencia. Las experiencias se han centrado en radares aeroportados (como el Airsar, operado por el JPL), o en algunas misiones del *Space Shuttle* (Dobson, 2000).

7.3. Características del suelo y el agua

De los párrafos anteriores se deduce que los suelos rugosos y secos tendrán un mayor coeficiente de retro-dispersión y, por tanto, aparecerán con tonos claros en las imágenes radar. Si la señal se reduce, manteniendo otras condiciones constantes, se tratará normalmente de suelos más húmedos. En suelos secos la capacidad de penetración del radar aumenta hasta llegar a varios metros si la longitud de onda es suficientemente larga (fig. 2.20). Cuando se presenten mezclas de vegetación y suelo, lo más probable es que la señal de retorno mezcle ambas cubiertas, complicándose bastante la interpretación de la señal. En experimentos con micro-ondas aeroportadas se ha observado que las bandas cortas (banda C) facilitan mejor información sobre la humedad de la cubierta vegetal (al tener menor capacidad de penetración), mientras en banda L puede detectarse más la vegetación del suelo (Paloscia, 1994).

Los núcleos de población, altamente rugosos a longitudes largas, también aparecen con tonos claros, lo que permite discriminarlos frente a los espacios cultivados limítrofes (Meliá y Sobrino, 1987).

En cuanto al agua, la región de las micro-ondas proporciona una cierta capacidad de penetración, siempre que el ángulo de incidencia sea bajo y se trabaje con longitudes de onda largas. El agua, casi siempre refleja especularmente el pulso recibido, con

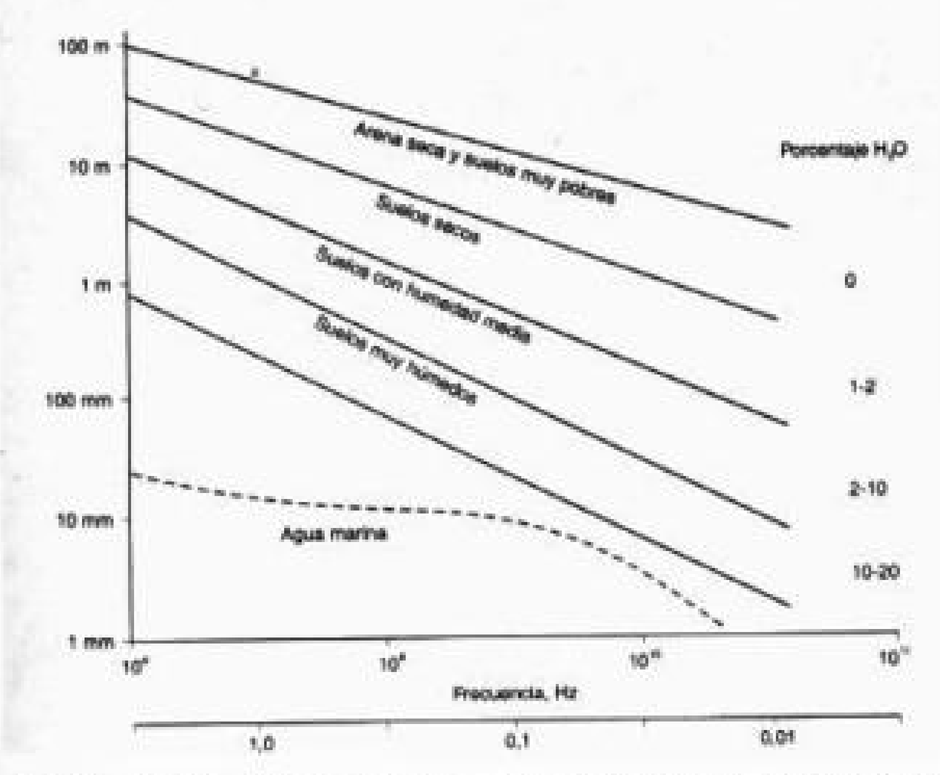


FIG. 2.20. *Relación entre humedad del suelo y capacidad de penetración del radar a distintas longitudes de onda.* (Adaptado de Trevett, 1986.)



FIG. 2.21. *Imagen del estrecho de Gibraltar adquirida por el ERS-1. Se observan varias olas de gran radio, provocadas por fenómenos mareales y la diferente salinidad entre el Mediterráneo y el Atlántico.* (Cortesía: ESA.)

lo que el retorno es bastante bajo. Ahora bien, si existe una cierta rugosidad superficial, por ejemplo oleaje, puede manifestarse en la imagen radar, siempre que el ángulo de incidencia sea bajo (fig. 2.21). Esta aplicación es muy útil para detectar anomalías en la superficie, por ejemplo las causadas por descargas incontroladas de petróleo (ver fig. 3.30). A partir de variaciones menores en la altura del oleaje, medido con altímetros de micro-ondas de elevada exactitud, puede obtenerse información de los fondos oceánicos, y, a partir de la rugosidad superficial, los vectores de dirección y velocidad del viento (fig. 2.22).

Respecto al hielo y nieve, el pulso de retorno es muy dependiente de las condiciones del material. La edad, composición y compacidad de la capa de hielo, su rugosidad, geometría interna y temperatura son factores destacados en el coeficiente de retro-dispersión finalmente detectado por el sensor.

8. Interacciones de la atmósfera con la radiación electromagnética

Hasta aquí hemos considerado la interacción de la radiación electromagnética con las diversas coberturas terrestres como si este proceso se desarrollara en el vacío. Obviamente, esta suposición es falsa, puesto que entre el sensor y la superficie terrestre se interpone la atmósfera, que interfiere de formas diversas en el flujo radiante.

Como es sabido, la atmósfera se compone de gases —dióxido de carbono, oxígeno, ozono, nitrógeno y argón, principalmente—, vapor de agua y aerosoles. Entre estos componentes, el CO_2, ozono y vapor de agua son los principales responsables de la interacción con la energía electromagnética. Su efecto es triple: (1) absorción de la energía en determinadas bandas del espectro, lo que limita la observación espacial a aquellas bandas en donde esta absorción es menos intensa; (2) dispersión, de determinados flujos, en función de su longitud de onda, y (3) emisión, como todo cuerpo caliente, que tiene su mayor importancia en el infrarrojo térmico. Estos procesos introducen modificaciones, en ocasiones muy severas, en la radiación originalmente propagada entre la cubierta y el sensor.

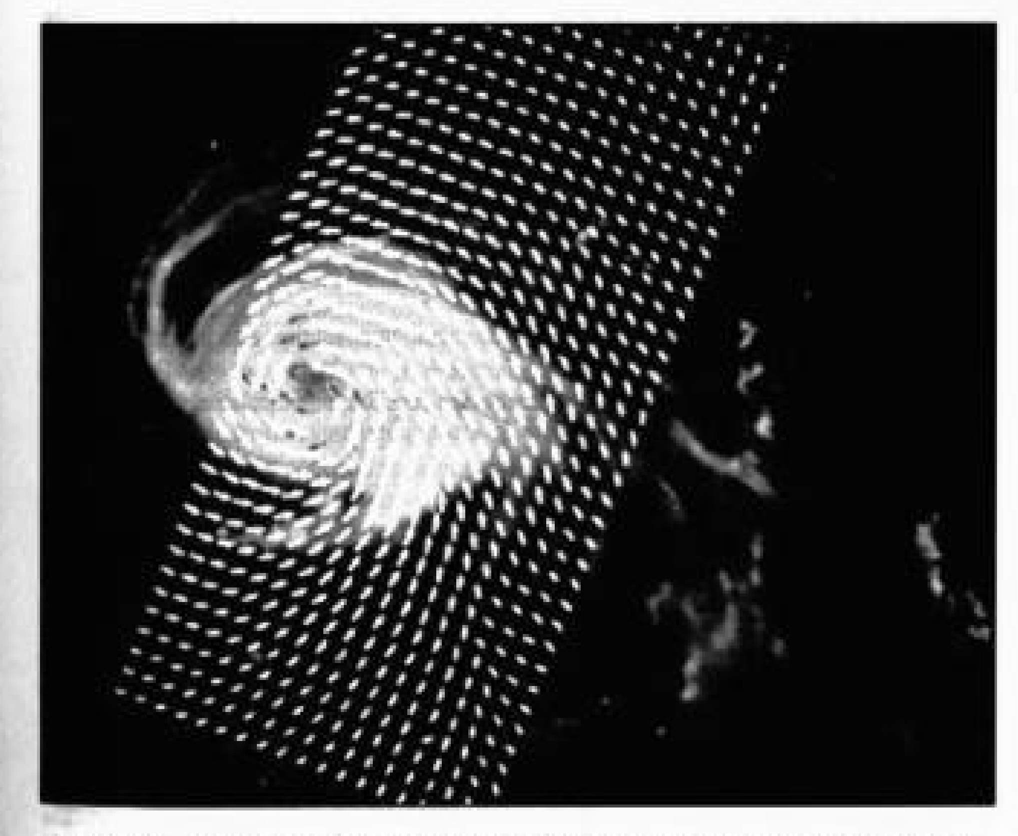


FIG. 2.22. *Imagen del satélite Meteosat del huracán Emily (agosto de 1993) a la que se ha superpuesto un campo de vientos generado por el dispersómetro del ERS-1.*

8.1. Absorción atmosférica

La atmósfera se comporta como un filtro selectivo a distintas longitudes de onda, de tal forma que en algunas bandas del espectro elimina prácticamente cualquier posibilidad de observación remota. Los principales causantes de esta absorción son:

— Oxígeno molecular (O_2), que filtra las radiaciones ultravioleta por debajo de 0,1 μm, así como pequeños sectores en el infrarrojo térmico y las micro-ondas.
— Ozono (O_3), responsable de la eliminación de la energía ultravioleta, inferior a 0,3 μm, así como en un sector de las micro-ondas (en torno a 27 mm).
— Vapor de agua, con una fuerte absorción en torno a 6 μm, por encima de 27 μm y otras menores entre 0,6 y 2 μm.
— Dióxido de carbono (CO_2), que absorbe en el infrarrojo térmico (> 15 μm), con importantes efectos en el infrarrojo medio, entre 2,5 y 4,5 μm.
— Aerosoles atmosféricos, que principalmente absorben en el espectro visible (ver fig. 3*).

Como consecuencia de esta absorción, la observación espacial se reduce a determinadas bandas del espectro, conocidas como ventanas atmosféricas, en donde la transmisividad de la atmósfera es suficientemente alta (fig. 2.23). Las principales ventanas atmosféricas son las siguientes: (1) espectro visible e IRC, situada entre 0,35 y 1,35 μm; (2) varias en el SWIR de 1,5 a 1,8 μm, y de 2,0 a 2,4 μm, (3) en el IRM: 2,9 a 4,2 μm, y de 4,5 a 5,5 μm; (4) en el IRT, entre 8 y 14 μm, y (5) en las micro-ondas, por encima de 20 mm, en donde la atmósfera es prácticamente transparente.

Estas ventanas atmosféricas son idóneas para realizar procesos de teledetección, por lo que el diseño de los sensores espaciales tiende a ajustarse a estas bandas, evitando interferencias extrañas al fenómeno que pretende observarse, salvo la presencia de nubes, que absorben en todo el espectro óptico.

Si se pretende, por el contrario, observar la atmósfera en lugar de la superficie terrestre, los sectores espectrales más convenientes son, precisamente, aquellos en donde la absorción atmosférica es alta. Bajo este enfoque, lo que se pretende es derivar a partir de teledetección estimaciones de la concentración en la atmósfera de distintos

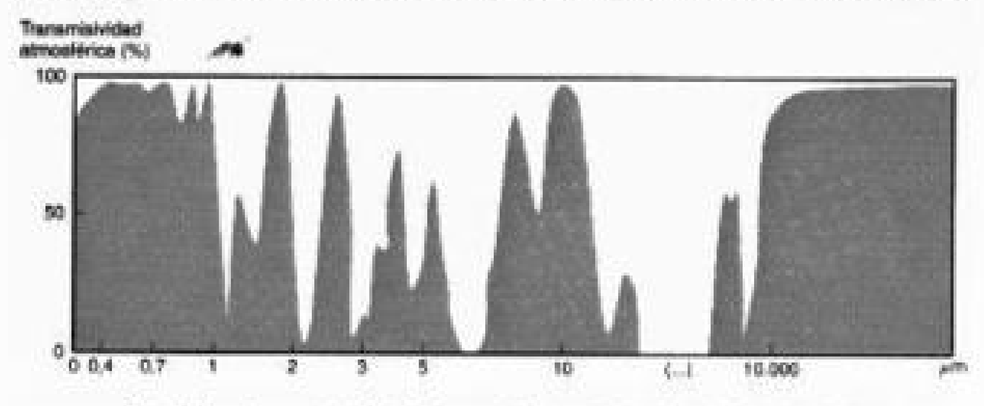


Fig. 2.23. *Transmisividad de la atmósfera a distintas longitudes de onda.*

gases, analizando sus espectros de absorción (Sobrino, 2000, cap. 5). La importancia que estos componentes gaseosos tienen sobre el clima del planeta ha llevado a enfatizar estos estudios de teledetección atmosférica en los últimos años, especialmente en el marco de los programas para el estudio del cambio climático global (França *et al.*, 1995; Kaufman *et al.*, 1990; King *et al.*, 1999). Especial importancia, en este contexto, han tenido los estudios mediante teledetección de emisiones procedentes de incendios forestales (Ferrare *et al.*, 1990; Watson *et al.*, 1990; Wilkinson *et al.*, 2000)

Cuando se pretende realizar una observación de las condiciones de la atmósfera, habitualmente se sitúan las bandas de observación precisamente en las regiones del espectro de alta absorción. Éste es el caso de los satélites meteorológicos, que habitualmente incluyen una banda en la región de absorción del vapor de agua (por ejemplo, el Meteosat cuenta con una banda entre 5,7 y 7,1 μm: ver fig. 3.4). El mismo enfoque se aplicó al diseño de los sensores TOMS *(Total Ozone Mapping Spectrometer)* a bordo de varios satélites norteamericanos, y GOME *(Global Ozone Monitoring Experiment)*, incluido en el satélite europeo ERS-2, que fueron ideados para cartografiar la capa de ozono, por lo que observan la región del ultravioleta, en donde este gas ofrece una alta absorción.

Cuando la variable de interés no ofrece una absorción total a una determinada región del espectro, como es el caso de los aerosoles, suelen utilizarse otras técnicas de análisis, por ejemplo la comparación multibanda con referencia a superficies de baja radiancia (agua profunda, zonas en sombra), si bien resultan más precisos los métodos basados en observación multiangular (lo que permite estimar el espesor óptimo atmosférico) o multipolarización (King *et al.*, 1999). En el primer capítulo cabría citar las observaciones pioneras del ATSR *(Along Track Scanning Radiometer)* a bordo del ERS, y las mas recientes del POLDER (en el satélite japonés ADEOS) y el MISR (en la carga útil del satélite Terra), que más tarde comentaremos.

8.2. Dispersión atmosférica

Como hemos dicho, el efecto de absorción se intenta paliar situando las bandas de observación en regiones del espectro donde la transmisividad atmosférica sea alta. Por ello, salvo en caso de coberturas nubosas, el intérprete no requiere dedicarle una atención especial. Mucho más complejo, sin embargo, es solucionar el efecto de dispersión causada por la atmósfera, presente —en mayor o menor grado— en cualquier imagen adquirida con sensores remotos.

La dispersión de la radiación electromagnética es causada por la interacción entre ésta y los gases y partículas atmosféricas en suspensión. La reflexión consiguiente a ese choque supone un aporte adicional a la radiancia proveniente de la superficie terrestre (luz atmosférica), lo que implica una reducción de la radiancia directa y un aumento de la difusa. Puesto que las partículas atmosféricas son muy variables en el tiempo y en el espacio, resulta muy complejo cuantificar su influencia final en la imagen adquirida por el sensor. Pese a ello, convendrá tener en cuenta este factor, especialmente cuando se pretenda convertir los valores digitales de la imagen a parámetros físicos (cap. 6, apdo. 2.3), o se aborden estudios multi-temporales (cap. 7, apdo. 3).

Los principales causantes de la dispersión atmosférica son los aerosoles y el va-

FIG. 2.24. *Dispersión atmosférica a distintas longitudes de onda.* (Adaptado de Campbell, 1987.)

por de agua. Los aerosoles son partículas en suspensión de origen muy diverso: oceánico —debidas al movimiento de las aguas—, o continental, polvo en suspensión o partículas emitidas por combustión. Tienen una notable importancia en el clima terrestre, tanto por su efecto absorbente como dispersor, modificando las propiedades de las nubes, el albedo terrestre y la química atmosférica (King *et al.*, 1999). En función de su origen y características poseen muy variados tamaños, lo que implica distintos tipos de dispersión, ya que ésta es muy dependiente de su diámetro. De esta forma, se habla de dispersión *Rayleigh*, causada por partículas muy pequeñas, de diámetro inferior a la longitud de onda; dispersión *Mie*, cuando se trata de partículas de diámetro similar a la longitud de onda, y de dispersión no selectiva, cuando se mencionan las partículas de mayor tamaño.

La dispersión *Rayleigh* afecta a las longitudes de onda más cortas (fig. 2.24). Es la más conocida y la de mayor influencia en teledetección, causante, por ejemplo, del color azul del cielo. En fotografía aérea es muy claro su efecto por el tono azulado que presentan los fotogramas cuando se realizan desde cierta altura. Cualquier observador distante puede comprobar este resultado, especialmente en los meses de verano, cuando se difumina el paisaje al divisarlo a largas distancias (calima).

En cuanto a la dispersión *Mie*, es también dependiente de la longitud de onda, si bien en menor grado que la anterior. Aerosoles y polvo atmosférico son los principales responsables de este tipo de dispersión, aunque también está presente en incendios forestales o en brumas costeras. Por último, la dispersión no selectiva afecta por igual a diversas longitudes de onda. Por esta razón, las nubes o nieblas tienden a aparecer blancas, ya que dispersan por igual toda la luz visible.

Los procesos de dispersión son muy complejos y difíciles de cuantificar en la imagen resultante. Normalmente no se dispone de datos coetáneos a la adquisición de



ésta, por lo que la corrección atmosférica se basa en relaciones entre elementos de la propia imagen (cap. 6, apdo. 2.3). Esta estimación puede ser burda en algunos casos, y dificulta, en última instancia, el uso de las imágenes adquiridas por sensores espaciales como medida cuantitativa de parámetros bio-físicos.

8.3. Emisión atmosférica

El efecto de emisión atmosférica resulta fundamental en el trabajo dentro del infrarrojo térmico, si se pretenden obtener mediciones de temperatura a partir de las imágenes espaciales. Al igual que cualquier cuerpo por encima del cero absoluto, la atmósfera emite energía, por lo que ese parámetro debe considerarse para separarlo de la emitancia espectral proveniente del suelo.

Las correcciones atmosféricas en el térmico (efectos de absorción y emisión) se han abordado habitualmente analizando la absorción diferencial de la atmósfera en dos bandas contiguas del infrarrojo térmico. Se denominan algoritmos de ventana partida (*split window*), que tendremos ocasión de comentar más adelante (cap. 6, apdo. 2.4). También puede estimarse el componente atmosférico a partir de la observación desde dos ángulos distintos (nadiral y oblicuo), por ejemplo a partir de imágenes del ATSR (Sobrino, 2000, pp. 184 y ss).

CAPÍTULO 3

SENSORES Y SATÉLITES DE TELEDETECCIÓN

«Tras de un amoroso lance, y no de esperanza falto,
volé tan alto, tan alto, que le di a la caza alcance.»

SAN JUAN DE LA CRUZ, *Poesía Completa*

1. Tipos de sensores

Como ya se indicó en el primer capítulo, un sistema de teledetección requiere, al menos, tres componentes: foco energético, superficie terrestre y sensor. Del primero y segundo se trató en el epígrafe sobre principios físicos. En éste se aborda el estudio de las características del sensor y de la plataforma que lo sustenta.

Entre las variadas formas de clasificar los sensores remotos, una de las más habituales considera su procedimiento de recibir la energía procedente de las distintas cubiertas. En este sentido, se habla de dos tipos de sensores: (1) pasivos, cuando se limitan a recibir la energía proveniente de un foco exterior a ellos, y (2) activos, cuando son capaces de emitir su propio haz de energía. Estos últimos son, lógicamente, más flexibles, puesto que no dependen tanto como los primeros de las condiciones exteriores al sistema sensor-Tierra.

Una ulterior clasificación entre los sensores pasivos considera su procedimiento para grabar la energía recibida. De acuerdo a ello, puede hablarse de sensores fotográficos, óptico-electrónicos y de antena. Los primeros resultan muy familiares, puesto que se basan en las mismas técnicas aplicadas en la fotografía convencional. El resto son peor conocidos por el gran público, si bien sistemas similares se utilizan rutinariamente: cámaras de vídeo, equipos de barrido o *scanners* en exploración médica, y radiómetros de micro-ondas en radio difusión.

En cuanto a los sensores activos, el equipo más conocido es el radar, bastante utilizado en aplicaciones militares, así como en control del tráfico aéreo. El radar trabaja en la región de las micro-ondas. Por su parte, el lidar opera con luz polarizada (láser) en el espectro óptico.

Antes de comentar con mayor detenimiento cada uno de estos sensores conviene analizar algunos conceptos previos que nos sirven para valorar la utilidad de la infor-

mación que proporcionan, y que resultarán útiles para planificar posteriormente su empleo en distintos problemas medioambientales.

2. Resolución de un sistema sensor

De acuerdo con algunos autores, podemos definir la resolución de un sistema sensor como su habilidad para discriminar información de detalle (Estes y Simonett, 1975). Esta definición engloba varios aspectos que merecen un comentario más detallado. Por un lado, se habla de resolución de un sistema sensor, indicando que este concepto se refiere al conjunto del equipo y no a cada una de sus partes. Dicho de otra forma, la resolución de un sensor depende del efecto combinado de sus distintos componentes. Una mejora en la lente —por ejemplo— no supondrá necesariamente adquirir fotografías con mayor resolución, si no se acompaña de una película de mayor sensibilidad, o no se modifican las condiciones de exposición.

Los términos de la definición «discriminar» e «información de detalle» merecen también una breve reflexión. Ambos son relativos al propósito y al entorno geográfico del proyecto que se esté abordando. La discriminación refiere a la capacidad de distinguir un objeto de otros. Esa distinción puede referirse a una simple determinación de que está ahí (detección) o a una delimitación precisa de su contorno (identificación). Lógicamente, la segunda tarea requiere mayor resolución espacial que la primera (Robin, 1998), ya que un objeto puede detectarse por sus efectos en la radiancia global observada (por ejemplo, el brusco aumento de temperatura que implica una erupción volcánica), pero para identificarlo con detalle (localizar con precisión el cráter) será necesario que el mínimo objeto que identifica el sistema sea mucho más pequeño que el tamaño del propio cráter.

En cuanto al significado de «información de detalle», conviene considerar que se refiere no sólo al detalle espacial que proporciona el sensor, sino también al número y anchura de las bandas del espectro que alberga, a su cadencia temporal, y a su capacidad para distinguir variaciones en la energía que detecta (Campbell, 1996). Todas estas dimensiones son de interés para discriminar cubiertas o establecer modelos de significado físico. En definitiva, el concepto de resolución implica diversas manifestaciones, las más habituales en la literatura especializada han sido la espacial, espectral, radiométrica y temporal. En los últimos años a éstas podemos añadir también la resolución angular, que haría referencia a la capacidad de un sistema de observar el mismo objeto desde distintas posiciones. A continuación comentaremos con más detalle cada una de ellas.

2.1. Resolución espacial

Este término designa al objeto más pequeño que puede ser distinguido sobre una imagen. En un sistema fotográfico, suele medirse como la mínima separación a la cual los objetos aparecen distintos y separados en la fotografía. Se mide en milímetros sobre la foto —o metros sobre el terreno—, y depende de la longitud focal de la cámara y de su altura sobre la superficie. En los sensores óptico-electrónicos se prefiere utilizar el concepto de campo de visión instantáneo (*instantaneous field of view*, IFOV). El IFOV se define como la sección angular, medida en radianes, observada en un momento determinado por el sensor. En lugar de esta definición, habitualmente suele utilizarse la distancia sobre el terreno que corresponde a ese ángulo, que puede calcularse a partir de él, conociendo la distancia del suelo al sensor.[1] Esa distancia se corresponde al tamaño de la mínima unidad de información incluida en la imagen, que se denomina píxel (del inglés *picture element*). Ésta es la medida más generalizada de resolución espacial, aunque también se emplean otros términos más complejos, como ERE (*effective resolution element*) o EIFOV (*effective instantaneous field of view*), que consideran la señal detectada como una función modulada compuesta (Townshend, 1980).

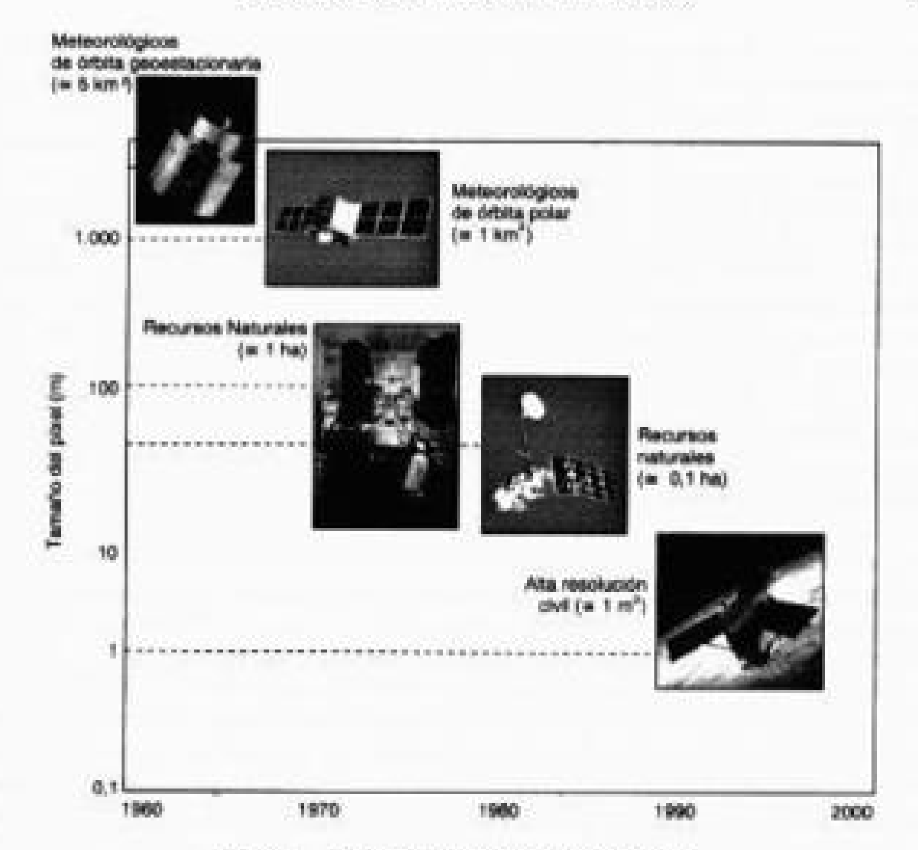


FIG. 3.1. *Tendencias en la resolución espacial.*

En cualquier caso, conviene considerar que la resolución espacial de un sensor óptico-electrónico depende de varios factores, como son la altura orbital, velocidad de exploración, y número de detectores. En cuanto a los sensores de antena, su resolución depende del radio de abertura, de la altura de la plataforma, y de la longitud de onda a la que trabajen. Cuanto mayor sea el radio, y menor la altitud y la longitud de onda, la resolución será tanto más detallada.

La resolución espacial de los sensores de observación terrestre en funcionamiento recoge un rango bastante amplio (fig. 3.1). Los satélites que cuentan con mayor resolu-

1. $d = 2H \tan(IFOV/2)$, siendo d el tamaño en el terreno de cada unidad de información (píxel) y H la altura de observación.

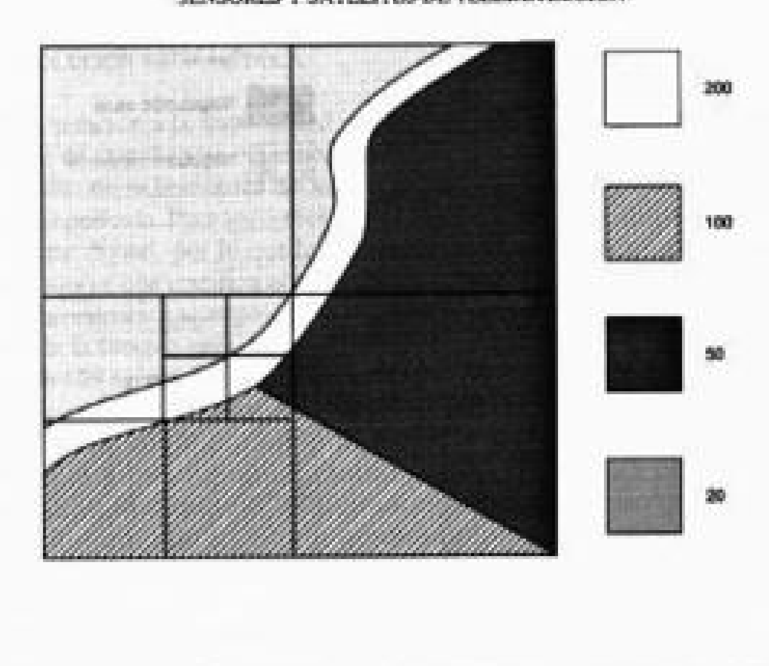
ción ofrecen un detalle espacial próximo a 1 × 1 m, mientras los de recursos naturales, diseñados para adquirir información sobre áreas muy heterogéneas, suelen contar con resoluciones comprendidas entre los 6 × 6 m del sensor pancromático IRS-1C, hasta los 120 × 120 m del canal térmico del Landsat-TM. Otro grupo de sensores, orientado hacia aplicaciones más globales, como el IRS-Wifs, Modis, Seawifs, SPOT-Vegetation o NOAA-AVHRR, facilitan píxeles de un tamaño comprendido entre 200 y 1.100 m de lado. En el extremo de este abanico estarían los satélites meteorológicos de órbita geoestacionaria (Meteosat, GOES, GMS), que al ofrecer una visión global de la superficie terrestre, proporcionan escaso detalle espacial, con píxeles de hasta 5 km de lado. En el futuro cercano está previsto continuar con el lanzamiento de satélites comerciales (recientemente se ha lanzado el Quickbird, y está activo desde 1999 el Ikonos-2, y desde 2000 el EROS A1), que ofrecen imágenes de muy alta resolución espacial (entre 0,61 y 4 m). Como ya vimos en el primer capítulo, esta mayor disponibilidad de imágenes de alta resolución permitirá ampliar al rango actual de aplicaciones de esta técnica, entrando en dominios anteriormente reservados a los medios aéreos de observación.

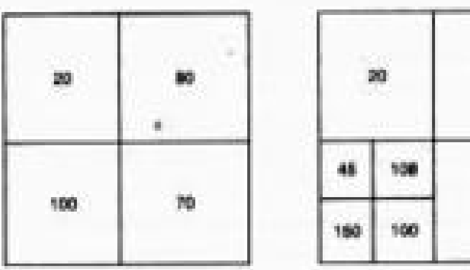
La resolución espacial tiene un papel protagonista en la interpretación de la imagen, por cuanto marca, de alguna forma, el nivel de detalle que ésta ofrece. Parece obvio decir que sólo serán identificables sobre la imagen elementos que superen el tamaño de varios píxeles, si bien pueden detectarse rasgos de tamaño similar o incluso más pequeño al del píxel cuando exista suficiente contraste radiométrico.

En consecuencia, la resolución espacial está en estrecha relación con la escala de trabajo y con la fiabilidad finalmente obtenida en la interpretación. Cuanto menor sea el tamaño del píxel, menor también la probabilidad de que éste sea un compuesto de dos o más cubiertas fronterizas. Un píxel mixto estará definido por una señal intermedia a las distintas cubiertas que lo componen. En consecuencia, puede no asemejarse a ninguna de ellas, lo que dificultará notablemente su correcta identificación (fig. 3.2). Sin embargo, en el caso concreto de algunas cubiertas, singularmente las urbanas, se ha comprobado que incrementar la resolución espacial puede afectar negativamente a la interpretación, cuando ésta se realiza digitalmente, al incrementar excesivamente la heterogeneidad interna en algunas categorías (Cushnie, 1987; Green, 2000; Townshend y Justice, 1981). En lo que se refiere a análisis visual, queda fuera de toda duda el interés de mejorar la resolución espacial para facilitar una interpretación más certera de la imagen (Hopkins *et al.*, 1988).

2.2. Resolución espectral

Indica el número y anchura de las bandas espectrales que puede discriminar el sensor. En el capítulo anterior se puso en evidencia el interés de contar con información multi-espectral; esto es, de registrar simultáneamente el comportamiento de los objetos en distintas bandas del espectro. En este sentido, un sensor será tanto más idóneo cuanto mayor número de bandas proporcione, ya que facilita la caracterización espectral de las distintas cubiertas. A la vez, conviene que esas bandas sean suficientemente estrechas, con objeto de recoger la señal sobre regiones coherentes del espectro. Bandas muy amplias suponen registrar un valor promedio, que puede encubrir la diferenciación espectral entre cubiertas de interés (fig. 3.3).





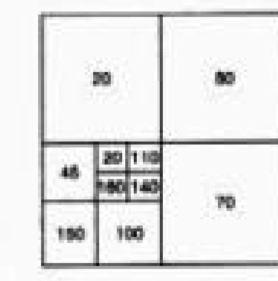


FIG. 3.2. *Al aumentar la resolución espacial, la señal recogida por el sensor resulta más cercana de las condiciones reales de la cubierta.*

Entre los sensores espaciales, la menor resolución espectral corresponde al radar y a los sistemas fotográficos. El primero trabaja normalmente en un solo canal, mientras las cámaras fotográficas han ofrecido principalmente películas pancromáticas (1 banda), siendo menos frecuentes las películas en color natural o infrarrojo color (3 bandas). Por su parte, los sensores óptico-electrónicos ofrecen un mayor rango de bandas, desde las 3 del SPOT-HRV (verde, rojo e infrarrojo cercano, aumentando hasta 4 en la última versión de este sensor) hasta las 220 ofrecidas por el sensor Hyperion, a bordo del satélite EO-1. Hasta hace solamente dos años, la observación de un número elevado de bandas espectrales (lo que se denomina habitualmente teledetección hiperespectral) estaba reducida a sensores aero-portados. Sin embargo, el lanzamiento del MODIS, con 36 canales en el dominio óptico y térmico del espectro, y del Hyperion, centrado únicamente en el espectro solar (0,4 a 2,5 μm), ha permitido ampliar notablemente las posibilidades de estas técnicas, abriéndose un futuro muy prometedor en el análisis de los recursos terrestres, como luego tendremos ocasión de comentar (cap. 7, apdos. 1.6 y 5.11.3).

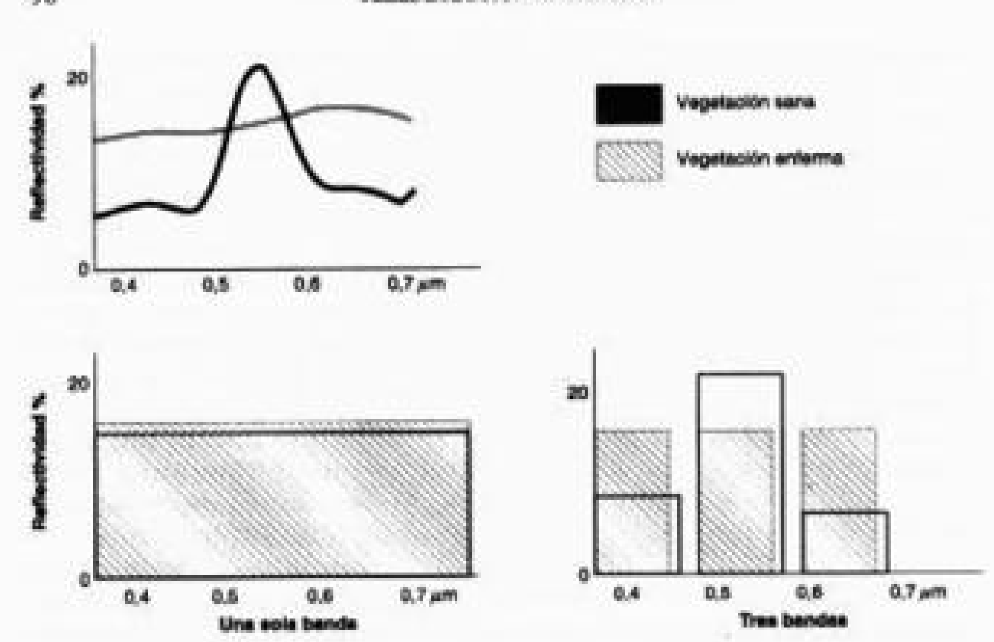


FIG. 3.3. *Efecto de la resolución espectral en la discriminación de cubiertas. Una banda pancromática sólo recoge una señal promedio, que no permite distinguir entre vegetación sana y enferma, mientras esta distinción es factible con una observación multiespectral.*

La elección del número, anchura y localización de las bandas que incluye el sensor está estrechamente relacionada con los objetivos de su diseño. Para un sensor dedicado a fines meteorológicos, basta situar una sola banda en el visible, puesto que no existen diferencias cromáticas en las nubes. Por el contrario, será conveniente que incluya una o dos bandas en el térmico (que le permitan conocer la temperatura de dichas nubes), y otra en el infrarrojo medio, en donde puede observarse el contenido de humedad en la atmósfera. Ésta es, precisamente, la distribución de bandas que recoge el sensor a bordo del satélite europeo Meteosat (fig. 3.4). Por el contrario, la observación minera requiere múltiples bandas en el visible, infrarrojo cercano y medio.

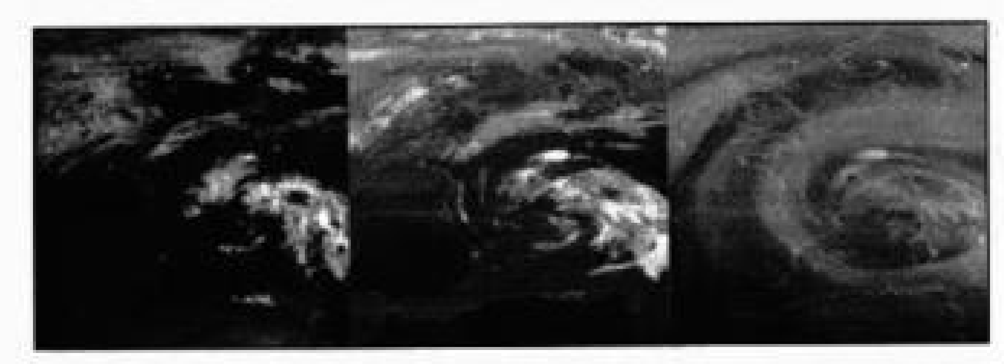
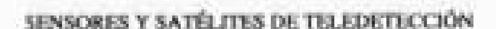


FIG. 3.4. *Ejemplo de las bandas espectrales adquiridas por el satélite Meteosat: visible, térmico e infrarrojo medio (absorción del vapor de agua).* (Cortesía: ESA.)



2.3. Resolución radiométrica

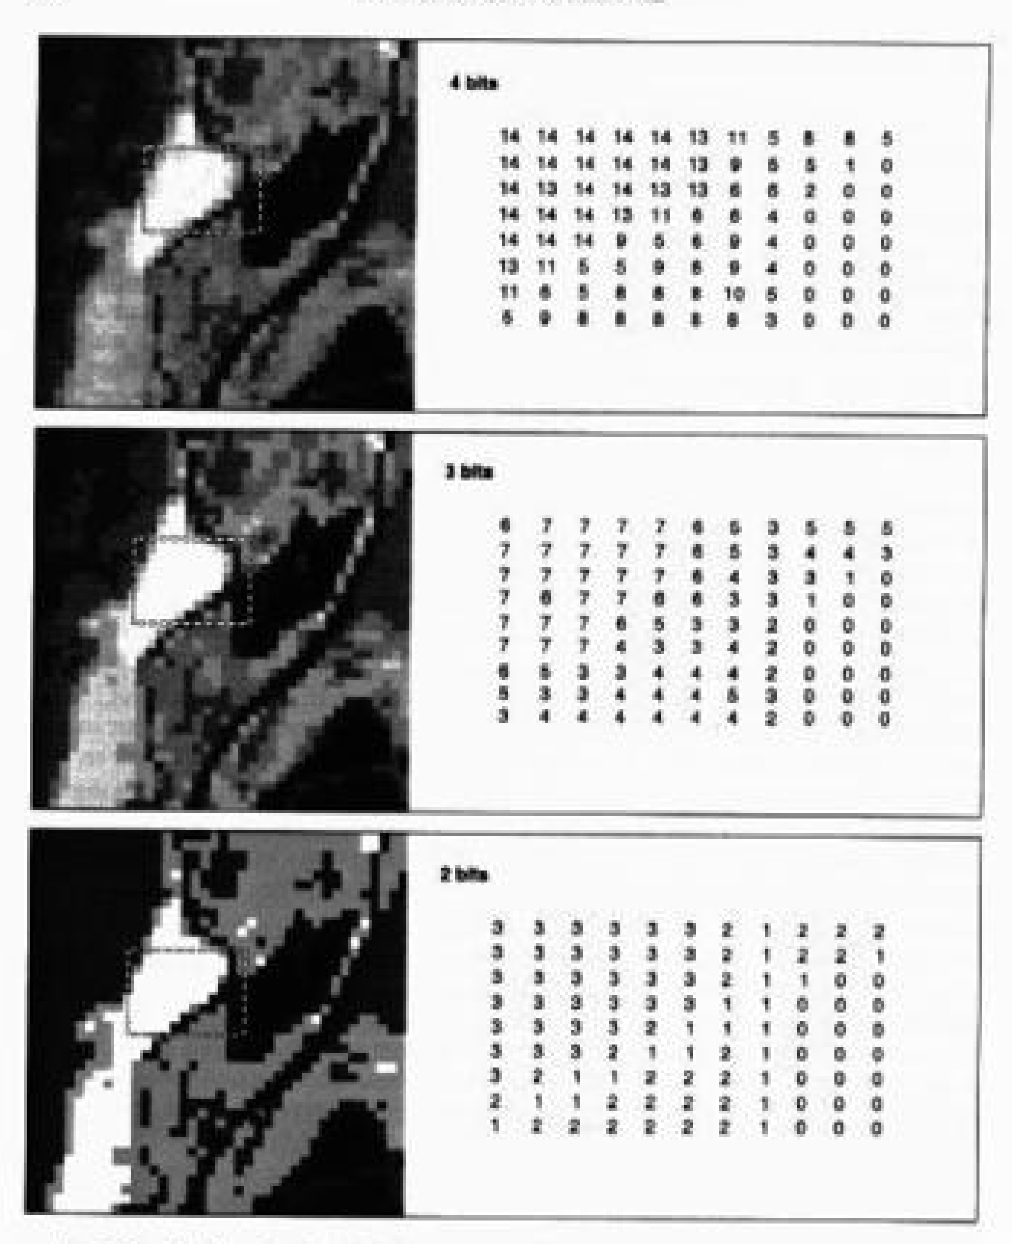
Hace mención a la sensibilidad del sensor, esto es, a su capacidad para detectar variaciones en la radiancia espectral que recibe. En el caso de los sistemas fotográficos, la resolución radiométrica del sensor se indica por el número de niveles de gris recogido en la película. Para los óptico-electrónicos, la imagen habitualmente se presenta en formato digital, por lo que la resolución radiométrica suele identificarse con el rango de valores que codifica el sensor (fig. 3.5). Por cuanto se trata de codificación digital, habitualmente se expresa esa resolución en el número de bits que precisa cada elemento de la imagen para ser almacenado. Inicialmente, los Landsat-MSS ofrecían un rango de 128 niveles de codificación (7 bits, $2^7 = 128$) por píxel, con 64 (6 bits) para el infrarrojo cercano. Actualmente, la mayor parte de los sistemas ofrecen 256 niveles por píxel (8 bits), con la excepción del NOAA-AVHRR, que trabaja con 1.024 niveles (10 bits), el Ikonos, que codifica hasta 2.048 valores (11 bits), y el MODIS y los radares del ERS y Radarsat, que discriminan hasta 65.536 valores (16 bits). Ésta será la resolución estándar para los futuros sensores de observación terrestre.

La resolución radiométrica, como ocurre con las dos anteriormente vistas, resulta de notable ayuda en la interpretación de imágenes, especialmente cuando realizamos análisis digital. Es preciso considerar que el número de niveles de gris que son capaces de discriminar nuestros ojos no excede de 64, mientras las tonalidades de color no superan las 200.000. Algunos autores estiman que basta con 16 niveles por color (4.096 tonalidades) para garantizar un análisis visual adecuado (Beaven, 1988), por lo que parece superfluo contar con 256 valores digitales por banda (16,8 millones en una combinación coloreada de 3 bandas). Sin embargo, cuando la interpretación es digital, el ordenador aprovecha todo el rango disponible, con lo que una mayor resolución radiométrica puede permitir discriminar objetos con niveles muy similares de reflectividad, que no serían separables con otros sensores menos sensibles (fig. 3.6).

2.4. Resolución temporal

Este concepto alude a la frecuencia de cobertura que proporciona el sensor. En otras palabras, se refiere a la periodicidad con la que éste adquiere imágenes de la misma porción de la superficie terrestre. El ciclo de cobertura está en función de las características orbitales de la plataforma (altura, velocidad, inclinación), así como del diseño del sensor, principalmente del ángulo total de abertura. Conviene tener en cuenta que la resolución temporal efectiva dependerá también de las condiciones atmosféricas, ya que con sensores ópticos o térmicos no podremos observar áreas cubiertas por nubes, por lo que en algunas zonas la cadencia de imágenes útiles puede ser notablemente más baja que el ciclo de adquisición del sensor. Para obviar de alguna manera estos problemas, los sensores más modernos incluyen la capacidad de observación no vertical (lo que se denomina sensores «enfocables»), facilitando así la adquisición de datos sobre una zona de interés desde una órbita próxima. Éste es el caso de los sensores a bordo de los satélites SPOT o Ikonos.

La cadencia temporal de los sistemas espaciales varía de acuerdo a los objetivos fijados para el sensor. Los satélites meteorológicos están obligados a ofrecer una informa-



14	14	14	14	14	13	11	5	8	8	5
14	14	14	14	14	13	9	5	5	1	0
14	13	14	14	13	13	6	6	2	0	0
14	14	14	13	11	6	6	4	0	0	0
14	14	14	9	5	6	9	4	0	0	0
13	11	5	5	9	8	9	4	0	0	0
11	6	5	8	8	8	10	5	0	0	0
5	9	8	8	8	8	8	3	0	0	0

6	7	7	7	7	6	5	3	5	5	5
7	7	7	7	7	6	5	3	4	4	3
7	7	7	7	7	6	4	3	3	1	0
7	6	7	7	6	6	3	3	1	0	0
7	7	7	6	5	3	3	2	0	0	0
7	7	7	4	3	3	4	2	0	0	0
6	5	3	3	4	4	4	2	0	0	0
5	3	3	4	4	4	5	3	0	0	0
3	4	4	4	4	4	4	2	0	0	0

3	3	3	3	3	3	2	1	2	2	2
3	3	3	3	3	3	2	1	2	2	1
3	3	3	3	3	3	2	1	1	0	0
3	3	2	3	3	3	1	1	0	0	0
3	3	3	3	2	1	1	1	0	0	0
3	3	3	2	1	1	2	1	0	0	0
3	2	1	1	2	2	2	1	0	0	0
2	1	1	2	2	2	2	1	0	0	0
1	2	2	2	2	2	2	1	0	0	0

FIG. 3.5. *Niveles de gris y digitales correspondientes a tres resoluciones radiométricas.*

ción en períodos cortos de tiempo, ya que se dedican a observar un fenómeno muy dinámico. De ahí que la red de satélites geo-estacionarios (Meteosat, GOES, GMS) proporcione una imagen cada 30 minutos. Esta información se complementa con la obtenida a partir de los satélites meteorológicos de órbita polar, como el NOAA, que facilita imágenes cada 12 horas. Por el contrario, los satélites de recursos naturales ofrecen una cadencia mucho menor: entre los 16 días del Landsat y los 31 días del ERS.



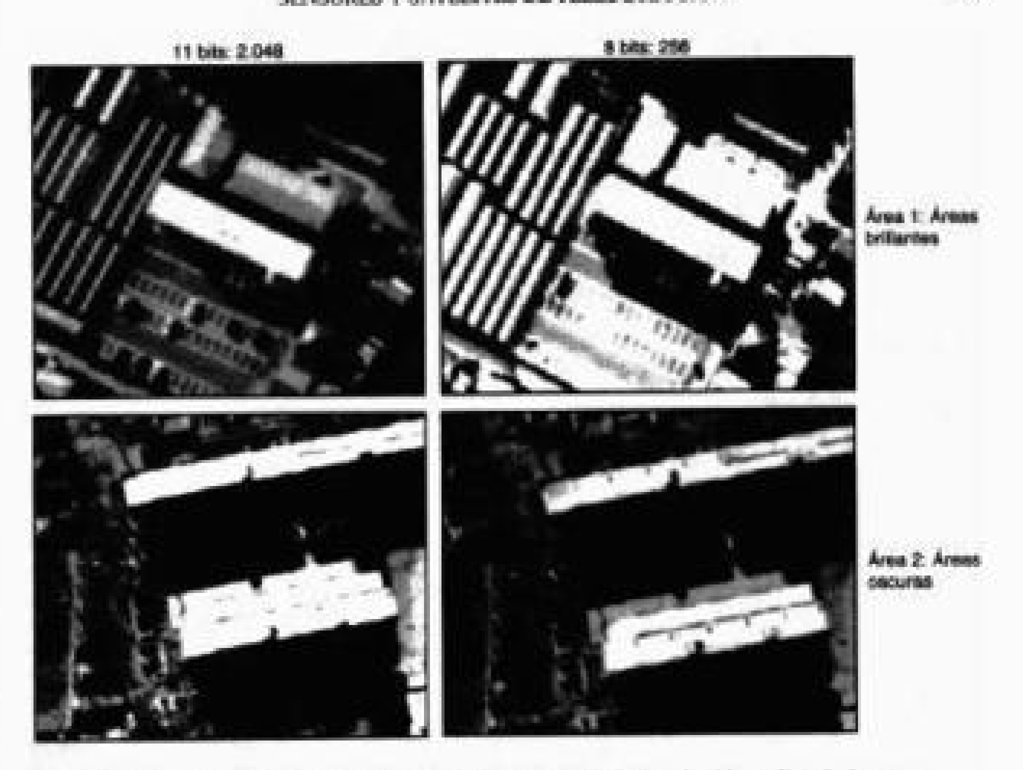


FIG. 3.6. *Imágenes Ikonos que ilustran el interés de la resolución radiométrica para discriminar tipos de superficie. En el fragmento superior sólo se distinguen los dos tipos de tejado en la imagen de mayor resolución radiométrica, mientras en la inferior se distinguen los coches en sombra.* (Cortesía: Indra Espacio.)

2.5. RESOLUCIÓN ANGULAR

Es un término relativamente reciente, que refiere a la capacidad de un sensor para observar la misma zona desde distintos ángulos (Diner *et al.*, 1999: fig. 3.7). Tradicionalmente se ha asumido que las cubiertas presentan una reflectividad lambertiana, lo que implica que ofrecerían una señal similar independientemente del ángulo con que se observan. En la práctica no es así, especialmente para algunas superficies que presentan fuertes efectos de reflectividad bidireccional. Una manera de modelar estos efectos es observar la cubierta desde distintas posiciones, facilitando así su mejor caracterización. También la observación multiangular resulta de gran interés para estimar algunas variables atmosféricas, ya que al variar el ángulo de mira se está observando la superficie con distinto espesor atmosférico, variando en consecuencia los procesos de absorción y dispersión.

Hasta hace pocos años no había sensores disponibles que tuvieran esta capacidad de observación multiangular, por lo que los estudios sobre direccionalidad se basaban, bien en análisis con radiómetros de laboratorio, bien en sensores de amplio campo de barrido, como el NOAA-AVHRR, que observan la superficie con distintos ángulos según la posición de la órbita del satélite (en el caso del AVHRR el ciclo se repite cada 9

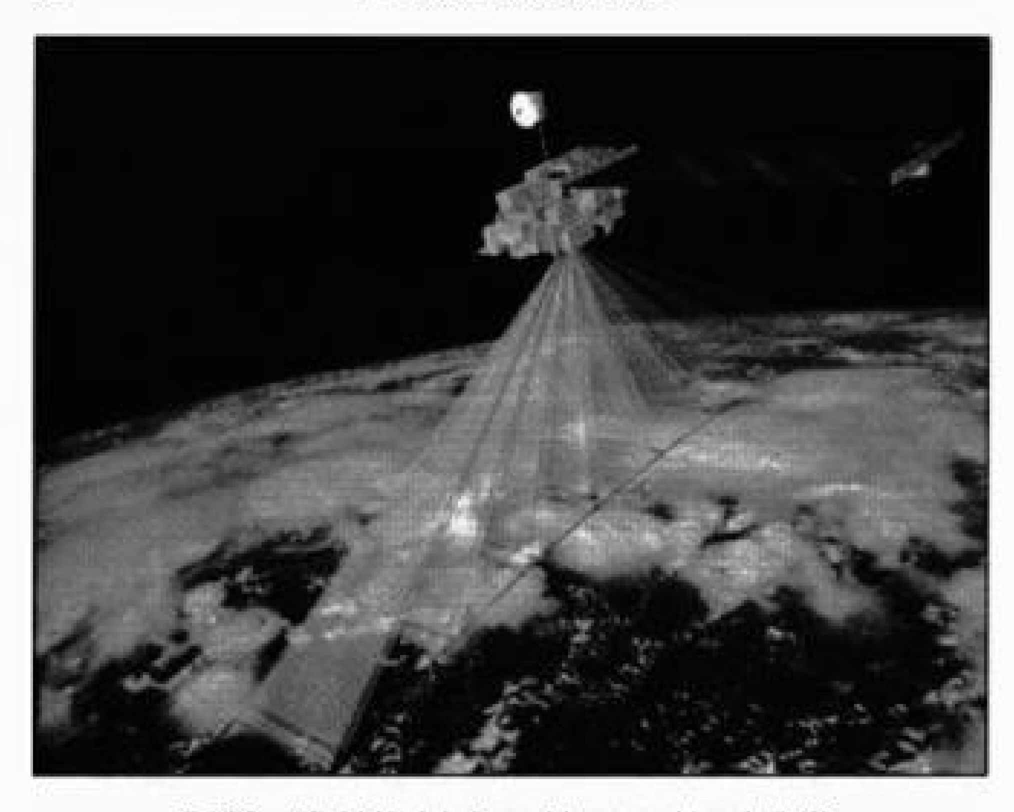


FIG. 3.7. *Adquisición de imágenes del sensor multiangular MISR.*

días). Ahora bien, esta última solución no es la más adecuada, pues puede haber severos cambios entre pasadas diarias del satélite. Por ello se han diseñado sensores que poseen específicamente capacidad de observación simultánea en varios ángulos. Éste es el caso del ATSR-2, lanzado en 1995 a bordo del ERS-2, el POLDER, instalado en el satélite japonés ADEOS en 1997, y el MISR, incluido sobre la plataforma Terra desde 1999. De ellos, el último proporciona características más avanzadas, al proporcionar información simultánea de nueve ángulos de observación, cubriendo además varias longitudes de onda del espectro.

2.6. Relaciones entre los distintos tipos de resolución

Conviene aclarar que estos cuatro aspectos de la resolución están íntimamente relacionados. A mayor resolución espacial, disminuye habitualmente la temporal, y es previsible que se reduzca también la espectral. El principal problema se encuentra en la transmisión de las imágenes a la superficie terrestre. El aumento en cualquiera de los cuatro tipos de resolución significa también un incremento considerable del volumen de datos a procesar, tanto por el sensor como por la estación receptora. Por esta razón, los primeros Landsat —dotados de resolución espacial, espectral y radiométrica

media— podían disponer de un sistema de grabación a bordo, que les permitía adquirir imágenes de áreas no cubiertas por la red de antenas receptoras. Al mejorar la resolución espacial, espectral y radiométrica con un nuevo sensor, los Landsat-4 y 5 ya precisaban estar constantemente conectados a una red de satélites de comunicaciones (denominados TDRSS), a través de los cuales enviaban las imágenes a las antenas receptoras. En caso de otras plataformas, como el satélite europeo ERS, sólo se registra información en el radio cubierto por las antenas receptoras, de ahí que no haya sido posible disponer de datos, de modo rutinario, de algunas zonas del mundo para las que no existían acuerdos de recepción.

Puesto que los diferentes tipos de resolución están relacionados, cada sistema de teledetección ofrece unas características particulares en función de los fines para los que se diseña. Si está orientado a la detección de fenómenos efímeros en el tiempo, deberá realzarse su cobertura temporal, aun a costa de perder resolución espacial, como ocurre con los satélites meteorológicos. Si, por el contrario, el sensor se orienta a exploración minera, el detalle espacial y espectral resulta más importante, reduciéndose entonces su ciclo temporal: un solo sistema no puede cubrir todas las expectativas.

Estos párrafos pueden contribuir a aclarar un aspecto de la resolución muchas veces malentendido. Con frecuencia se identifica la calidad del sensor con su resolución espacial, lo cual es acertado sólo en algunas aplicaciones (por ejemplo, catastro urbano o rural). Por el contrario, en otras será más acuciante mejorar otros tipos de resolución, como la temporal o espectral. Por ejemplo, la detección de incendios forestales o la evaluación de inundaciones no tendrían validez con sensores muy precisos espacialmente, pero que ofrecieran una imagen mensual, ya que entonces las estimaciones carecerían de interés práctico. Por esta razón, es cada vez más frecuente el uso de satélites meteorológicos —que tienen buena resolución temporal— para aplicaciones terrestres que no estaban contempladas en su diseño original (estimación de cosechas o seguimiento de la deforestación, por citar dos casos). Otras aplicaciones de la teledetección deben enfatizar la resolución espectral: por ejemplo, cuando se trate de discriminar cubiertas con un comportamiento radiométrico muy similar, sólo divergente en bandas muy particulares del espectro. La exploración minera requiere con frecuencia este tipo de sensores, que permiten también discriminar fiablemente diferentes cultivos o rendimientos.

3. Sensores pasivos

Los sensores pasivos se limitan a recoger la energía electromagnética procedente de las cubiertas terrestres, ya sea ésta reflejada de los rayos solares, ya emitida en virtud de su propia temperatura. De acuerdo a nuestra previa clasificación, puede establecerse una división en estos sensores en función del procedimiento que emplean para recibir la radiación procedente de los objetos. Antes se aludía a los sensores fotográficos, óptico-electrónicos y de antena. En el primer grupo estarían las cámaras fotográficas; en el segundo, los exploradores de barrido y de empuje, y las cámaras de vidicón, mientras los sensores pasivos de antena se conocen con el nombre de radiómetros de micro-ondas.

3.1. Cámaras fotográficas

Las cámaras fotográficas todavía siguen siendo el medio más utilizado de teledetección aérea, pero tienen una importancia bastante limitada en plataformas espaciales, al estar restringida la adquisición a la carga de película que puede incluirse en el satélite. Como es sabido, una cámara fotográfica registra la energía reflejada por un objeto sobre emulsiones fotosensibles, con el apoyo de un sistema óptico que permite controlar las condiciones de exposición. Dentro de esta configuración básica pueden establecerse numerosas variantes, en función de cuatro elementos: tipo de película, número de objetivos, ángulo de observación y altura de la plataforma.

Respecto al tipo de película, el más empleado en teledetección aérea es el film pancromático (blanco y negro), en el cual se recoge todo el espectro visible sobre una sola emulsión. En la película en color se mezclan distintas capas foto-químicas, cada una de las cuales es sensible a una banda del espectro visible, por lo que la discriminación de los objetos resulta más atinada. Menos conocidos en nuestro país son los filmes en infrarrojo blanco y negro —que recogen en tonos de gris la radiación correspondiente al infrarrojo cercano—, y en infrarrojo color, también denominado falso color, en donde se desplaza la escala de color natural, situándose entre el verde y el infrarrojo cercano.

En cuanto al número de objetivos, puede tratarse de una cámara mono o multibanda, según albergue una o varias regiones del espectro simultáneamente. En este segundo caso, la observación múltiple puede realizarse con dos modalidades: incorporando varios objetivos —cada uno de ellos con un filtro apropiado— en una sola cámara, lo que permite impresionar la misma imagen en diversas bandas del espectro (fig. 3.8); o bien, ensamblando varias cámaras sobre el mismo soporte, cada una de ellas con filtros y filmes apropiados, con lo que se obtendrían simultáneamente distintas fotografías de la misma zona.

En lo que atañe al ángulo de observación, conviene anotar la diferencia entre fotografía vertical, tomada perpendicularmente al terreno (con $\pm 5°$ de desviación permitida), y fotografía oblicua, con un ángulo de visión sensiblemente inferior a 90°. La primera se emplea, con el debido recubrimiento, para la restitución fotogramétrica, así como en estudios temáticos muy variados. La fotografía oblicua tiene principalmente un fin estético, aunque también puede reportar interesantes conclusiones para el estudio del relieve o los asentamientos humanos, entre otras facetas de interés científico.

Por último, la altura de observación permite distinguir entre fotografía aérea y espacial. Desde el punto de vista de su aplicación a estudios de medio ambiente, las diferencias más significativas entre ambas afectan a su resolución espacial, nitidez, cobertura del terreno y precisión geométrica. Las dos primeras son favorables a la fotografía aérea, y las dos últimas a las cámaras espaciales (por la menor influencia del relieve).

De acuerdo al contenido de esta obra, nos centraremos en el análisis de los programas de exploración fotográfica desde plataformas espaciales. Históricamente estas experiencias fueron las pioneras de teledetección desde el espacio. Las primeras fotografías espaciales de observación civil se obtuvieron durante la misión Mercury-4, a las que siguieron las adquiridas por las cápsulas Gemini y Apollo en los primeros años sesenta. En un primer momento estas fotografías se adquieren casi espontáneamente, pero más tarde, y ante la calidad de los resultados, se comenzaron a diseñar proyectos



FIG. 3.8. *Cámara multibanda MKF-6.* (Cortesía: R. Núñez de las Cuevas.)

dirigidos específicamente a la observación de los recursos naturales. Éste fue el caso de la misión Gemini GT-4 que incluyó el primer experimento programado de teledetección espacial, concretamente para aplicaciones geológicas.

A esta tentativa siguieron otras de gran interés, a bordo de diversas misiones Apollo, que sirvieron para preparar el terreno a otros programas dedicados exclusivamente a la observación terrestre. En este sentido, conviene destacar el papel del laboratorio espacial tripulado *Skylab*, activo, con diversas tripulaciones, durante 1973. En esta plataforma se incluyó un programa de observación terrestre bautizado como EREP *(Earth Resources Experiment Package)*, que incluía diversos sensores: un barredor multi-espectral, dos sensores de micro-ondas y dos sensores fotográficos. Estos últimos eran la cámara multi-espectral (S 190A), con seis objetivos sensibles a distintas longitudes de onda entre 0,4 y 0,9 μm, y la cámara de observación terrestre (ETC, *Earth Terrain Camera*), dotada de una gran focal (457 mm), que se diseñó para obtener fotografías de alta resolución (15 m) a 435 km de altitud (NASA, 1977). A partir de estas fotografías se realizaron estudios temáticos muy variados: cobertura del suelo, cartografía litológica, vegetación y cultivos (Hart, 1975; Links, 1976; NASA, 1977).

A consecuencia del éxito de esta experiencia se concibieron esperanzas de que las cámaras espaciales sirvieran como base para la restitución fotogramétrica —por procedimientos similares a los practicados con fotografía aérea—, remediando así la gran carencia mundial de cartografía básica. Hasta el momento se han diseñado tres

cámaras de alta precisión con estos fines: la cámara métrica RMK 20/23, la cámara de gran formato (LFC) y la cámara multi-espectral MKF-6.

La cámara métrica RMK 20/23 se construyó por la casa Zeiss para proporcionar fotografías estereoscópicas de gran precisión y elevada cobertura, con un formato convencional (23 × 23 cm). Fue incluida en la primera misión *Spacelab* de la Agencia Espacial Europea (1983), a bordo del transbordador espacial estadounidense. Esta misión permitió adquirir unas 1.000 fotografías con película pancromática e infrarrojo color sobre varias regiones del mundo, cubriendo una zona aproximada de 11 millones de km^2 (Konecny, 1986). La longitud focal era de 305 mm, lo que proporcionó una escala aproximada de 1:820.000 a 250 km de altura, con una resolución estimada entre 20 y 30 m. La cobertura estereoscópica se cifró en 60 %, aunque en áreas montañosas se extendió hasta el 80 %. Las restituciones practicadas a partir de estas fotografías se obtuvo cartografía básica a escala 1:100.000 (Schroeder, 1986).

Un ejemplo de este tipo de fotogramas puede analizarse en la figura 3.9. Se trata de un par estereoscópico enmarcado entre los Picos de Urbión y la Sierra de Ayllón, en la región central española, cubriendo un área aproximada de 15.000 km^2. Aquellos lectores familiarizados con la fotografía aérea, posiblemente queden fascinados al percibir el relieve de una zona tan extensa, contemplada desde 250 km de altura. Junto a los rasgos morfológicos que ofrecen estas fotografías, resulta también de gran interés su visión panorámica, global, de las cubiertas vegetales, sin olvidar su aplicación cartográfica, principal objetivo de esta misión. El cambio de orientación en las misiones del *Space Shuttle*, tras el desastre del *Challenger* en 1986, interrumpió el empleo de esta cámara.

Similar suerte corrió la cámara de gran formato (*Large Format Camera*, LFC). Diseñada por ITEK con la misma finalidad que la cámara europea (cartografía básica), su principal novedad consistía en ampliar el área observada, gracias a disponer de un formato de 23 × 46 cm (frente al 23 × 23 convencional). Esta cámara se empleó por vez primera en la misión 41-G del *Space Shuttle* (1984), obteniéndose una variada colección de fotografías con un recubrimiento de hasta el 80 %, lo que facilitó precisiones en altura de 30 m, a una escala 1:50.000 (Togliatti, 1986). La misma cámara ha sido empleada en otras misiones del transbordador espacial norteamericano, tanto con películas pancromáticas como color (Francis y Jones, 1984; Lulla, 1993).

Un buen ejemplo de la información adquirida por esta cámara aparece en la figura 3.10, que abarca unos 47.000 km^2 en el centro de España (la original comprende unos 62.000 km^2). La amplitud de la zona incluida en el fotograma permite percibir una visión global de la región centro, desde el embalse de Santa Teresa (Salamanca) hasta el parque nacional de las Tablas de Daimiel (Ciudad Real). La magnífica resolución espacial que ofrece la cámara LFC se pone aún más en evidencia gracias a la ampliación de esta imagen que ofrece la figura 3.11, situada sobre la ciudad de Madrid y Casa de Campo. Tras un análisis detallado podrán extraerse rasgos de gran interés sobre la imagen: morfología metropolitana, red viaria, expansión urbana, etc.

En las últimas misiones del transbordador norteamericano se han utilizado cámaras más convencionales, como la Hasselblad de 70 mm y Aerotechnika de 5 pulgadas. Recientemente se han comenzado experiencias con la cámara digital ESC (*Electronic Sill Camera*) que ofrece una resolución de 1024 × 1024 píxeles en blanco y negro, aunque se estudia su amplicación a la misma resolución en color y hasta

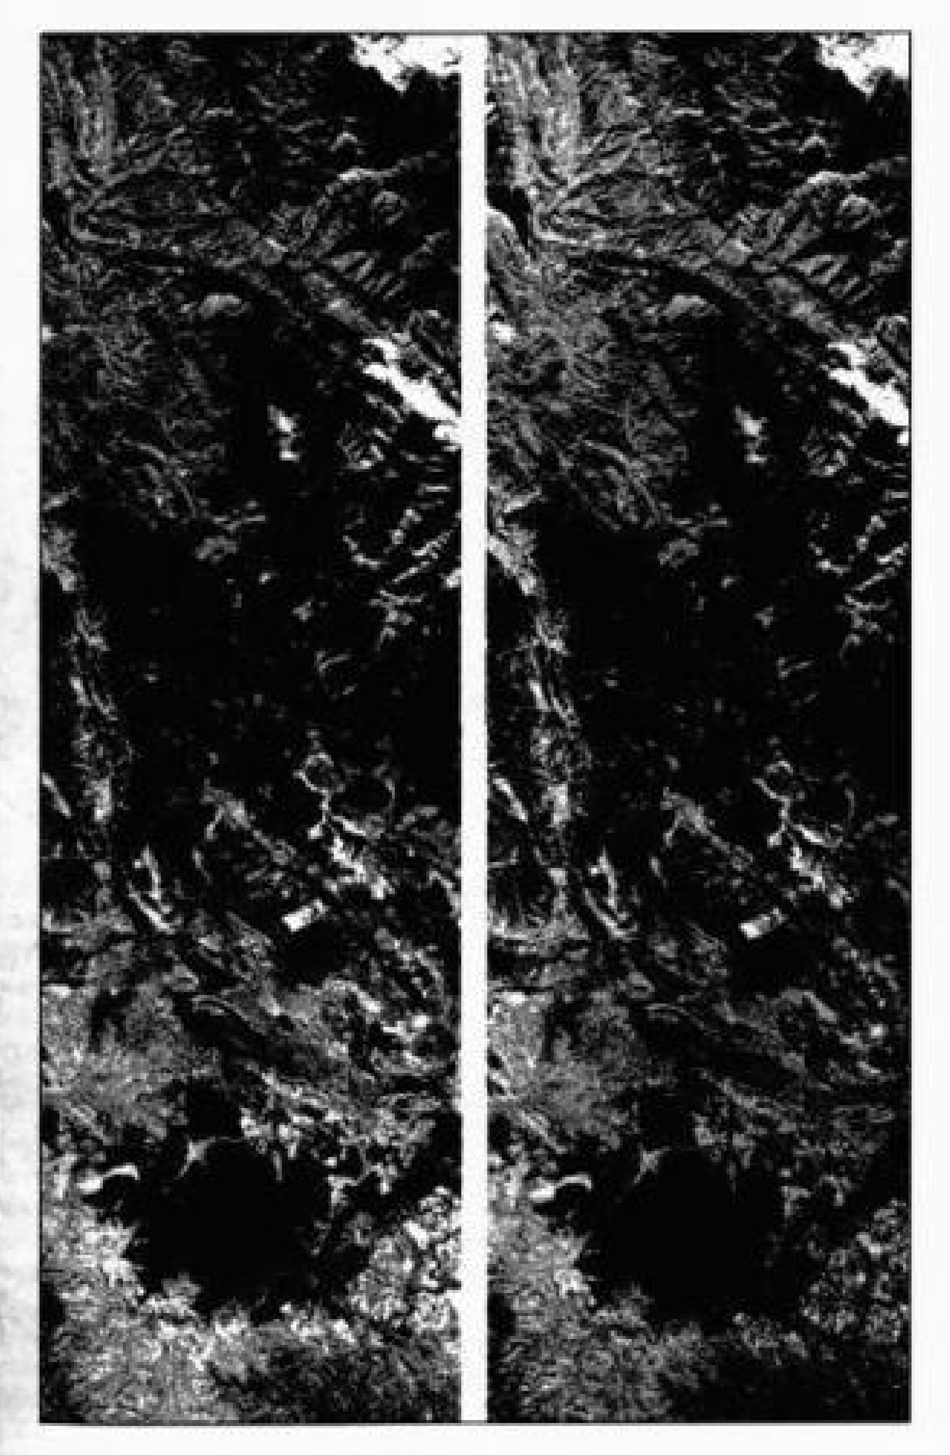


FIG. 3.9. *Par estereoscópico de la cámara métrica RMK 20/23 sobre los Picos de Urbión y pinares de Soria.* (Cortesía: R. Núñez de las Cuevas.)

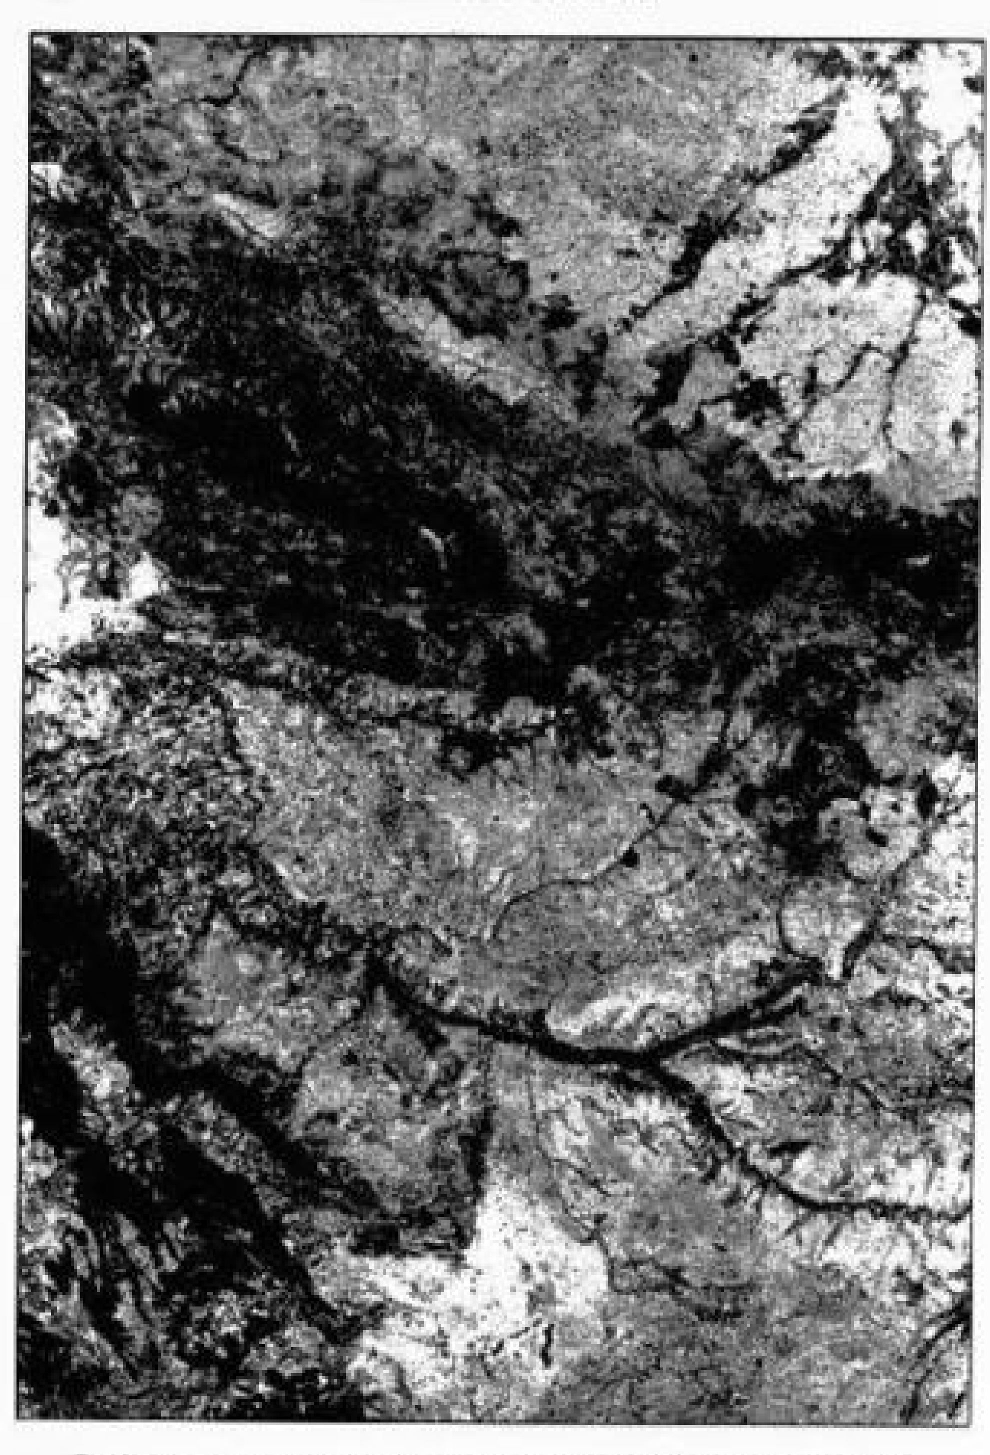


FIG. 3.10. *Fotografía de la cámara de gran formato (LFC) sobre el Sistema Central y Valle del Tajo.* (Cortesía: R. Núñez de las Cuevas - F. Doyle.)

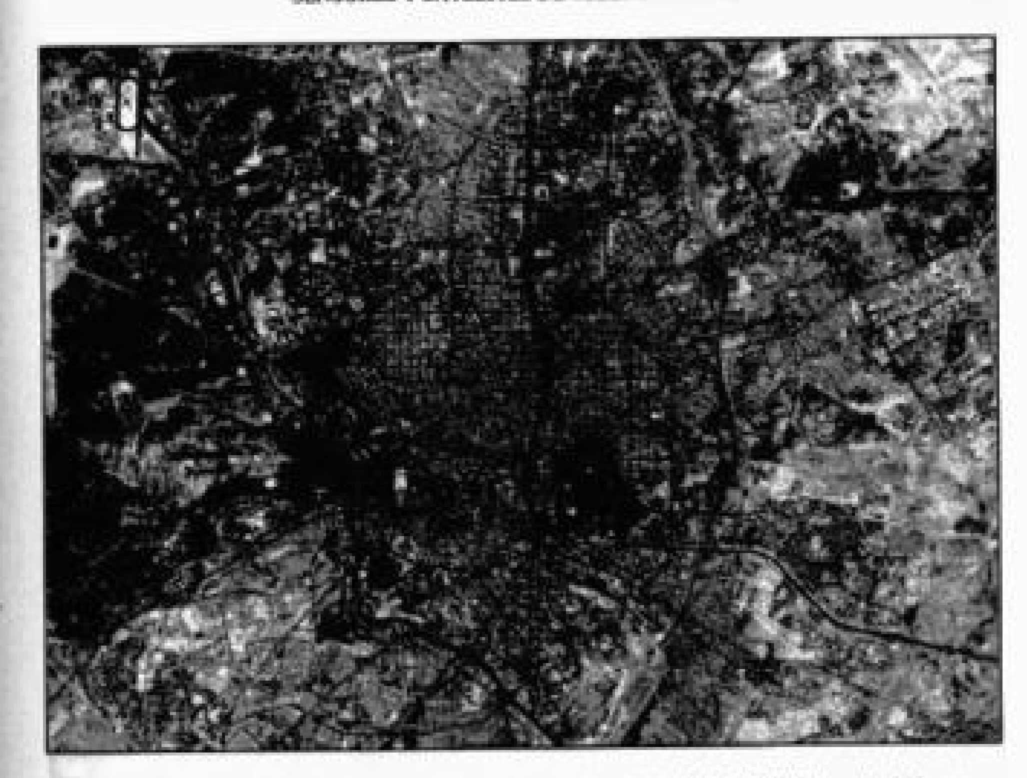


FIG. 3.11. *Ampliación de la fotografía anterior sobre la ciudad de Madrid y alrededores.*

2.048 × 2.048 en blanco y negro (Lulla, 1993). Las fotografías tomadas por las diversas misiones del *Space Shuttle* pueden adquirirse en el *Global Land Information System* (GLIS), un servidor web del *U.S. Geological Survey* que permite acceder a múltiples datos gestionados por este centro, así como a imágenes Landsat, CORONA y fotografías aéreas. La mayor parte de las fotografías almacenadas en este centro son en color natural, aunque una pequeña parte son en blanco y negro y otras en infrarrojo color. El archivo corresponde a las 55 misiones del transbordador espacial que han tomado fotografías de la superficie terrestre. Más recientemente se están comenzando a utilizar las fotografías de las misiones combinadas del *Space Shuttle* y la nave soviética Mir, especialmente en análisis de cambios ambientales (Lulla y Dessinov, 2000).

Desde el punto de vista del análisis de cambios en el paisaje resulta de gran interés la comercialización de fotografías tomadas por satélites militares estadounideses, gracias a una decisión de la Casa Blanca en 1995 (McDonald, 1995). Se trata de fotografías adquiridas por los satélites CORONA, ARGON y LANYARD, comprendidas entre 1960 y 1972, a lo largo de más de 100 misiones. Estas fotografías tienen formatos muy variados, dependiendo de las misiones. La resolución espacial varía entre 150 y 2 m, aunque son más habituales las comprendidas entre 2 y 10 m. Las escalas nominales varían entre 1:275.000 y 1:4.250.000, y el área abarcada por las fotografías varía entre 18 × 234 km, y 480 × 480 km. Como hemos indicado, las fotografías pueden

conseguirse a través del servidor del GLIS. Esperemos que en un inmediato futuro sigan desclasificándose las fotografías de satélites militares, ya que proporcionan niveles de resolución todavía mucho mayores que la observación civil.[2]

Los satélites rusos también han incluido diversos sensores fotográficos, algunas de alta precisión. Una de las más destacadas es la cámara multi-espectral MKF-6 (fig. 3.8), instalada a bordo de diversas misiones del satélite Soyuz. Dotada de seis objetivos, ha permitido obtener fotografías sobre seis bandas del espectro, del azul al infrarrojo cercano. También han sido muy empleadas las cámaras KFA-200, a bordo de los satélites RESURS-F, con una resolución espacial de 25-30 m y 3 bandas espectrales (verde, rojo e infrarrojo cercano), la pancromática KFA-1000, con resolución de 8-10 m, y la MKF-4, multiespectral con 12 a 14 m de resolución (Kramer, 1994). Estas fotografías facilitan una información muy valiosa para el estudio de los recursos naturales, hídricos y minerales (Sagdejew, 1982; Strain y Engle, 1993). Gracias a un acuerdo con la empresa norteamericana *Aerial Images, Inc*, y a través del servidor de imágenes Terraserver (www.terraserver.com), pueden conseguirse fotografías digitales del satélite ruso Cosmos. Este satélite está equipado con dos cámaras, la KVR-1000 que permite obtener hasta 2 m de resolución sobre un área de 160 km de lado, y la TK-350, con 10 m de resolución y 200 km de anchura (en este caso con capacidad estereoscópica). Ambas se digitalizan, comercializándose a través de Internet (se denominan imágenes SPIN-2). Un ejemplo de la calidad de estos datos puede observarse en la figura 3.12, que cubre el casco histórico de la ciudad de Alcalá de Henares. Los detalles que proporciona sobre la estructura y morfología urbana son perfectamente equiparables a la fotografía aérea.

3.2. Exploradores de barrido

Las características técnicas de los sensores fotográficos impiden que desde ellos se realice una cobertura sistemática de la superficie terrestre, por cuanto no facilitan una transmisión a distancia de las imágenes captadas. Por esta razón se han diseñado otro tipo de sensores, denominados genéricamente óptico-electrónicos, ya que combinan una óptica más o menos similar a la fotografía, con un sistema de detección electrónica, que evita la dependencia de una superficie sólida de grabación.

Entre estos sensores, los más habituales en teledetección espacial son los exploradores o rastreadores de barrido *(scanners)*. Un espejo móvil, que oscila perpendicularmente a la dirección de la trayectoria, les permite explorar una franja de terreno a ambos lados de la traza del satélite. La radiancia recibida por este componente óptico se dirige a una serie de detectores, que la amplifican y convierten a una señal eléctrica. Ésta, a su vez, se transforma a un valor numérico, que puede almacenarse a bordo o transmitirse a la red de antenas receptoras (fig. 3.13). La información recibida por estas antenas se graba en soporte magnético para su posterior proceso y distribución a los usuarios.

2. En la página web de la Federación de científicos americanos (FAS) se da amplia información sobre satélites de observación militar. Entre los actualmente disponibles destaca el GAMBIT con 0,5 y 0,1 m de resolución (www.fas.org/eye/index.html).

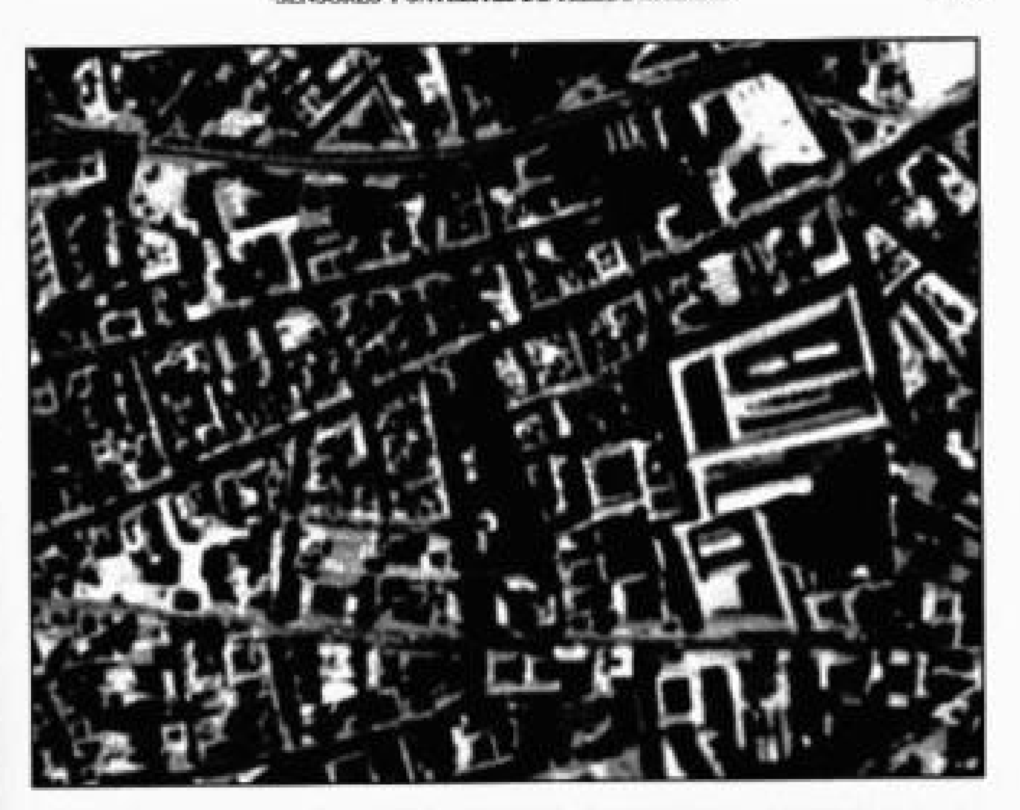


Fig. 3.12. *Imagen de la cámara KVR-1000 sobre la ciudad de Alcalá de Henares adquirida en 1987.* (Alcalá 87; origen: www.terraserver.com)

En suma, el sensor convierte una señal analógica, la radiancia recibida, en un valor digital, por lo que no puede hablarse propiamente de fotografías —aunque, en ocasiones, se presenten en formato fotográfico—, sino de imágenes digitales, en razón de su estructura interna. Estos valores numéricos pueden traducirse, de nuevo, en niveles de reflectividad o temperatura, conociendo los coeficientes de calibrado del sensor y las condiciones de adquisición. En definitiva, es posible realizar la conversión contraria, digital-analógica, para obtener los valores originalmente detectados por el sensor. Esto supone, en pocas palabras, que estos sensores, no sólo facilitan una representación gráfica, sino también una medición física de la superficie que observan.

El número y características de los detectores que incorpora un equipo de barrido es muy importante para explicar las condiciones de la imagen resultante. La señal enviada por el equipo óptico a estos detectores se muestrea a intervalos regulares, de tal forma que únicamente se graba un valor numérico cada cierta distancia. Ese intervalo marca el tamaño de la unidad mínima de información adquirida por el sensor, que se denomina píxel. En la mayor parte de los equipos de exploración por barrido, la señal recibida se descompone a bordo en varias longitudes de onda, cada una de las cuales se envía a un tipo especial de detectores, sensibles a ese tipo de energía. En ese caso se habla de exploradores de barrido multi-espectral, pues detectan la misma superficie

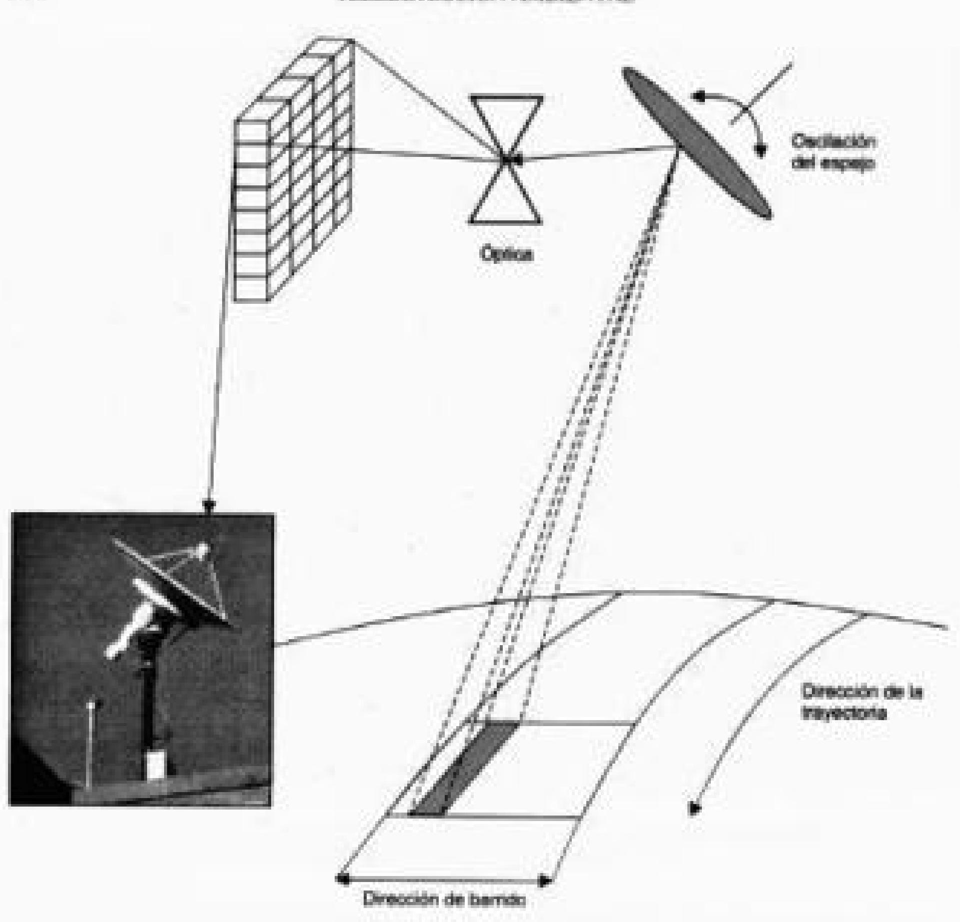


FIG. 3.13. *Diagrama de un explorador de barrido.*

de terreno en distintas bandas del espectro. El número y anchura de esas bandas —lo que hemos denominado resolución espectral— está en función del diseño del propio sensor: del número de detectores con que cuente, de su óptica, capacidad de almacenamiento y transmisión de datos, etc.

Las ventajas más claras de los equipos de barrido multi-espectral, en relación con los sensores fotográficos, pueden sintetizarse en los siguientes puntos:

1. Permiten ampliar la banda del espectro detectada a longitudes de onda mayores del visible. Las emulsiones fotográficas están limitadas al rango 0,4 a 0,9 μm (visible e infrarrojo reflejado), mientras los equipos de barrido pueden abarcar de 0,4 a 12,6 μm, incluyendo el SWIR, IRM e IRT.
2. Mayor facilidad en la calibración y en la corrección radiométrica de los datos.
3. Posibilidad de realizar coberturas sistemáticas, y de grandes espacios, gracias a su capacidad de transmitir datos en tiempo real.
4. Grabación digital de la información, que asegura su fiabilidad y permite su tratamiento asistido por ordenador.

Su principal problema hasta hace unos años era su menor resolución espacial respecto a los sistemas fotográficos, pero este inconveniente se está mitigando notablemente, gracias a los avances en la electrónica microscópica.

Gracias a las características arriba comentadas, los equipos de barrido multi-espectral se han incorporado sistemáticamente a las principales misiones de teledetección desde el espacio. Los más utilizados han sido los incluidos en los programas Landsat (MSS, *Multispectral Scanner*, TM, *Thematic Mapper*, y ETM, *Enhanced Thematic Mapper*), TIROS-NOAA (AVHRR, *Advanced Very High Resolution Radiometer*), Nimbus (CZCS, *Coastal Zone Color Scanner*), Skylab (S192), DMSP (*Operational Linescan System*, OLS), HCMM (HCMR, *Heat Capacity Mapping Radiometer*) y el soviético RESURS (*MSU-E* y *MSU-SK*), entre otros.

3.3. Exploradores de empuje

En los años ochenta se puso a punto una nueva tecnología de exploración, denominada «de empuje» *(pushbroom)*. En estos equipos se elimina el espejo oscilante, gracias a disponer de una cadena de detectores que cubre todo el campo de visión del sensor. Estos detectores se van excitando con el movimiento orbital del satélite, de ahí el nombre de explorador de empuje, puesto que se explora, en cada momento, una línea completa, desplazándose ésta simultáneamente con la plataforma (fig. 3.14). Los detectores sólidos que forman un explorador por empuje se denominan dispositivos de acoplamiento por carga *(Charge Couple Devices, CCD)*.

Esta tecnología permite aumentar la resolución espacial del sistema respecto a los barredores convencionales, gracias a eliminar la parte móvil, mientras se reducen algunos problemas geométricos que se producen en los barredores, caso de que se perdiera la sincronía entre el movimiento del espejo y el de la plataforma. Además no se requiere que los detectores sean interrogados una vez por píxel, como ocurre en los exploradores de barrido, sino sólo una vez por línea, lo que agiliza la detección y emisión de datos. Por otra parte tienen las mismas ventajas que los exploradores de barrido en cuanto a que la información es digital y corresponde a distintas bandas del espectro, mas allá del VIS.

Como contrapartida, uno de los problemas importantes que atañe a estos nuevos equipos es la difícil calibración de su cadena de detectores. Al aumentar notablemente su número, se precisa de complejos mecanismos de ajuste para que éstos traduzcan, de la misma forma, la señal recibida. Caso contrario, faltaría homogeneidad entre las columnas de la imagen, afectando a su calidad final. Otro problema aún no bien resuelto en estos sistemas es ampliar la información espectral que proporcionan, incluyendo al infrarrojo térmico. Hasta el momento presente se han diseñado equipos mono y multi-espectrales, limitados al VIS, IRC y SWIR. El trabajo en el térmico resulta mucho más complejo por el tipo de detectores que precisa, muy sensibles al calor y de difícil calibración.

Los exploradores de empuje se han ido incorporando en las dos últimas décadas a la mayor parte de los proyectos de teledetección espacial, a partir de la puesta en órbita del satélite SPOT (sensor HRV). Otros satélites con este tipo de sensores son el indio IRS (sensor PAN, LISS y WIFS), los norteamericanos EO-1 (ALI), Ikonos y Quickbird, y los japoneses MOS (MESSR) y JERS-OPS, entre otros muchos.

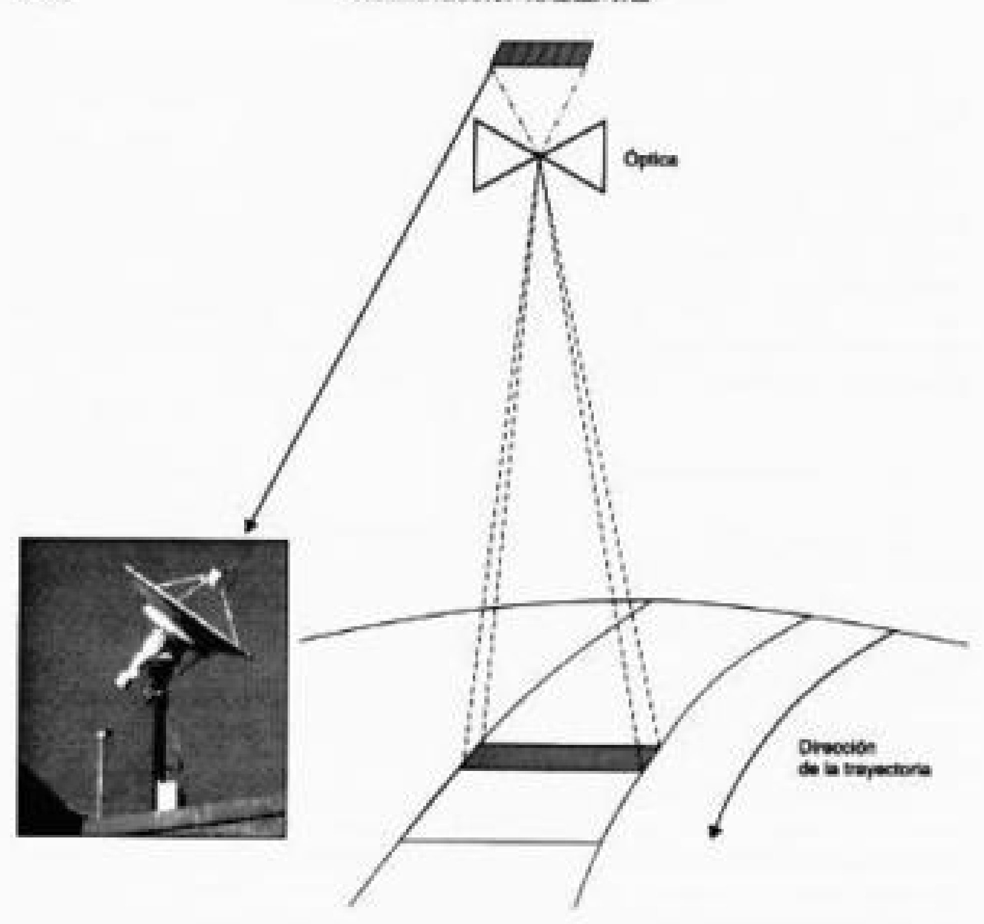


FIG. 3.14. *Diagrama de un explorador por empuje.*

3.4. CÁMARAS DE VÍDEO

Otro de los sistemas pasivos de mayor uso en estudios de recursos naturales es la cámara de vídeo, que puede trabajar en forma pancromática o multi-banda. La imagen es enfocada sobre un foto-conductor, construyéndose una réplica electrónica de la imagen original, que se mantiene en esa superficie hasta que el haz de electrones la barre de nuevo, restaurando así su equilibrio (fig. 3.15).

Este modelo de funcionamiento se modificó en el caso del RBV *(Return Beam Vidicon)*, a bordo de los primeros satélites Landsat. En estos sistemas, la señal de la cámara se derivaba de la porción no utilizada del haz de electrones, que retornaba a lo largo de la misma trayectoria que el rayo incidente, y era amplificado electrónicamente. Ese mecanismo permitió mejorar la resolución espacial de los equipos de barrido y del vidicón convencional, por lo que fue incluido en algunas misiones espaciales: Apollo, Mariner, TIROS, Nimbus, Bhaskara-1 y 2, así como en los tres primeros satélites de la serie Landsat.

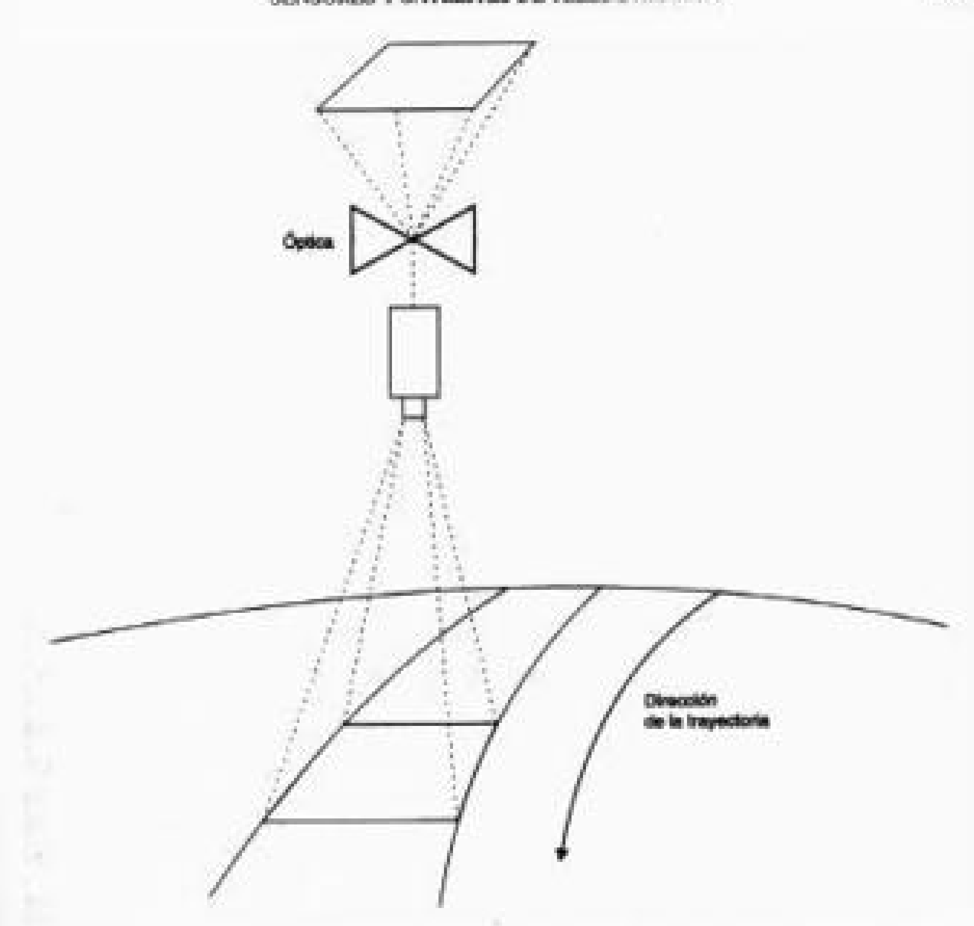


FIG. 3.15. *Diagrama de un sistema de vídeo.*

Más reciente resulta el empleo de las cámaras de vídeo digital como fuente de imágenes en proyectos de gran escala. La videografía se define así como una nueva técnica de teledetección, que permite obtener información calibrada con gran nivel de detalle y bajo coste (especialmente si se utilizan las cámaras convencionales). Su principal interés sobre la fotografía aérea es su inmediata disponibilidad y facilidad de manejo. Su principal inconveniente es la baja resolución (está limitado a un campo de visión no superior a 500 píxeles con las tecnologías convencionales), que obliga a tomar los datos desde baja altura (Linden, 2000).

3.5. RADIÓMETROS DE MICRO-ONDAS

Se trata de un sensor que opera en el rango del espectro correspondiente a longitudes de onda milimétricas, normalmente entre 6,8 y 90 GHz. Por ello, no está afectado por la situación atmosférica ni por las condiciones de iluminación.

El radiómetro está compuesto por un elemento direccional, un receptor, que per-

mite la detección y amplificación de las microondas, y un detector. Su gran desventaja estriba en la pobre resolución espacial que proporciona, ya que, al tratarse de un sensor de abertura circular, la resolución es inversamente proporcional al diámetro de abertura y directamente a la longitud de onda. En consecuencia, para poseer una adecuada resolución sería preciso contar con una antena de enormes proporciones, lo cual no es factible en misiones espaciales.

Pese a este problema, los radiómetros de micro-ondas se han utilizado con gran aprovechamiento para diversos estudios medioambientales (Choudhury *et al.*, 1994). Uno de los campos en donde ha mostrado mayor interés atañe a la cartografía de hielo y nieve, gracias a ser muy sensibles a las bajas temperaturas.[3] Esto ha permitido obtener información del estado de la capa de hielo, así como diferenciar tipos de nieve en función de su compacidad y temperatura. A este respecto, el sensor SSMR *(Scanning Multichannel Microwave Radiometer)*, a bordo del Nimbus-5 y 6, se ha empleado con gran eficacia para detectar movimientos de icebergs y para cartografía de capas de hielo. Un mapa térmico de ambos casquetes polares fue obtenido a partir de estas imágenes en 1977, revelando información de gran interés para el estudio de estas áreas, difícilmente accesibles por otros medios (Hall y Martinec, 1985). Los datos de los radiómetros de micro-ondas se han mostrado también muy convenientes para estimar las condiciones de humedad en el suelo y el estrés hídrico en la vegetación (Choudhury y Nicholson, 1992). La apertura a usos civiles de los datos adquiridos por el satélite militar DMSP *(Defense Meteorological Satellite Program)* facilita la continuidad de estas observaciones, ya que cuenta con un equipo muy similar al del Nimbus, denominado SSM/I *(Special Sensor Microwave Imager)*, que proporciona información en varias frecuencias, registrando tanto polarización horizontal como vertical. También la misión TRMM *(Tropical Rainfall Measuring Misión)* cuenta con un equipo de estas características, el TRMM *Microwave Imager* (TMI), diseñado para estimar la lluvia sobre el océano.

4. Sensores activos

4.1. Radar

Característica común de los sistemas activos es su capacidad de emitir un haz energético que, posteriormente, recogen tras su reflexión sobre la superficie que se pretende observar. Entre ellos, el sistema más conocido es el radar, radiómetro activo de micro-ondas, que trabaja en una banda comprendida entre 0,1 cm y 1 m. Cada píxel en una imagen radar representa el coeficiente de retro-dispersión de esa área sobre el terreno, siendo el valor almacenado tanto mayor cuanto más intensa sea la señal de retorno. Gracias a su flexibilidad —puede trabajar en cualquier condición atmosférica (fig. 3.16)—, el radar ha pasado a un primer plano en los programas de observación de la Tierra, obteniendo múltiples aplicaciones en la última década (Henderson y Lewis, 1998).

3. Recuérdese que, de acuerdo a la leyes de Planck y Wien [2.4 y 2.6], cuanto mayor sea la temperatura de una superficie, emitirá más intensamente a longitudes de onda más cortas. Por tanto, sólo las cubiertas más frías son perceptibles a estas longitudes de onda.

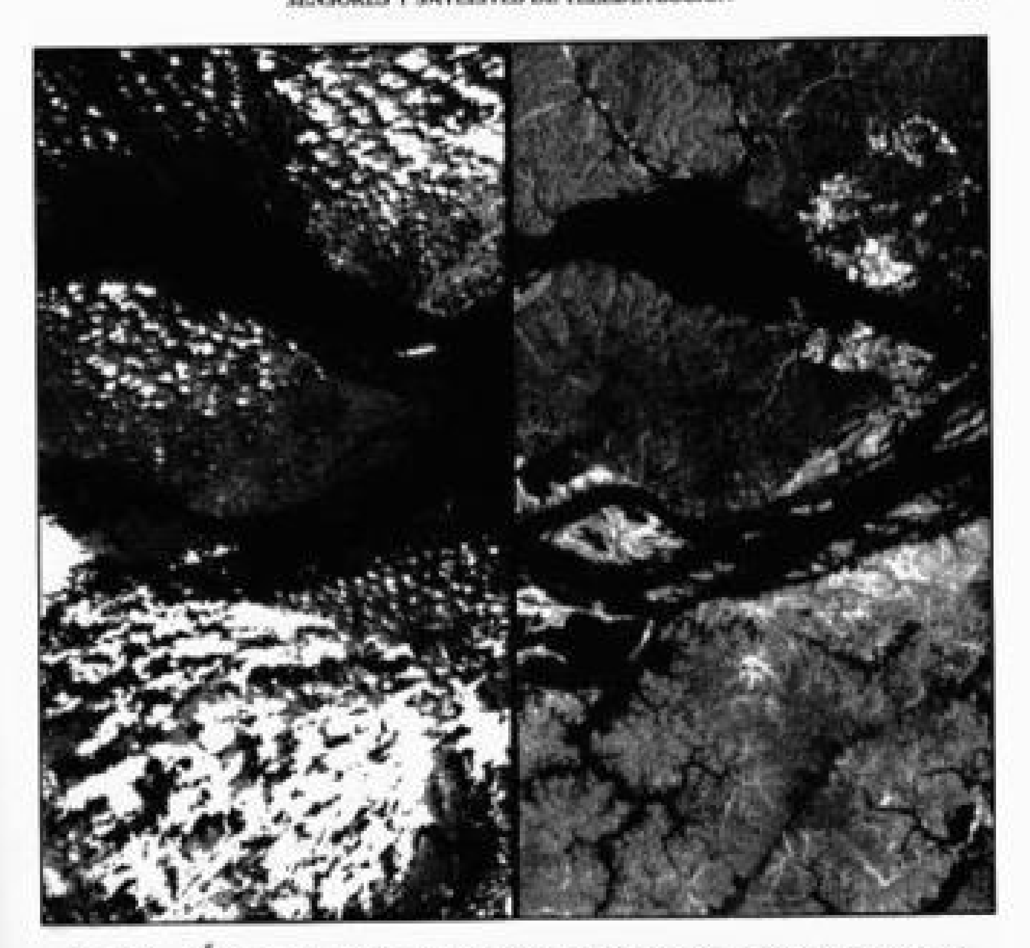


FIG. 3.16. *Imágenes adquiridas por el JERS-1 en 1993 sobre los alrededores de la ciudad de Manaos (Brasil). En la izquierda aparece uno de los canales ópticos del sensor OPS, mientras a la derecha figura una imagen del radar. Resulta evidente la capacidad de este último sensor para observar zonas cubiertas por nubes.* (Cortesía: NASDA.)

Las primeras experiencias con radar se desarrollaron sobre plataformas aéreas. El sistema más utilizado, en este contexto, fue el radar lateral aero-transportado (SLAR, *Side Looking Airborne Radar*), que mostró gran versatilidad respecto a la fotografía aérea, especialmente para estudios sobre áreas tropicales (Allan, 1983; Trevett, 1986).

El principal problema de estos sensores radica en su baja resolución, como consecuencia del escaso diámetro de la antena. La resolución espacial de un sistema de abertura circular puede calcularse como:

$$R_s = \frac{\lambda h}{\phi} \qquad [3.1]$$

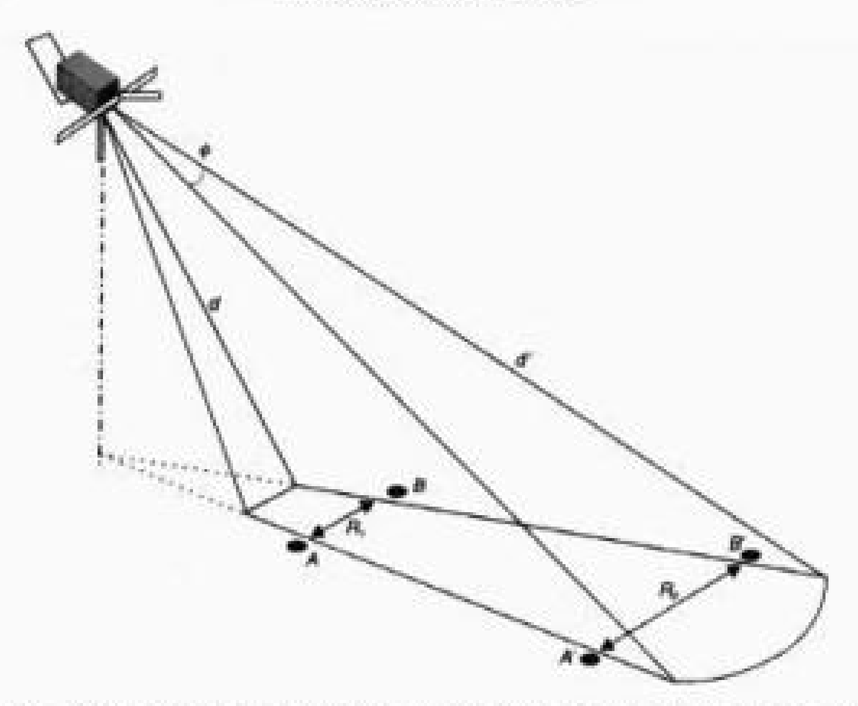


FIG. 3.17. *Resolución en acimut de un sistema radar.* (Adaptado de Lillesand y Kiefer, 1994.)

esto es, el tamaño del mínimo objeto identificable sobre la imagen está en relación directa con la longitud de onda λ y la altura de observación (h) e inversa con el diámetro de abertura ϕ. Esto anula el empleo de este sistema en plataformas espaciales, pues para lograr una resolución adecuada sería preciso contar con antenas de enormes proporciones.

Tal inconveniente, no obstante, puede obviarse con el empleo del radar de abertura sintética (SAR, *Synthetic Aperture Radar*). Su principio de operación se basa en el efecto Doppler, que afecta a la observación realizada cuando existe un movimiento relativo entre objeto y sensor. En el caso del SAR se registran los pulsos de un mismo punto de la superficie terrestre en dos momentos distintos de la trayectoria, con lo que la resolución es equivalente a la que se obtendría con una antena de similar longitud a la distancia existente entre ambos puntos (Elachi, 1987).

Tanto el radar aerotransportado como el espacial observan la superficie lateralmente. Este hecho, junto a las posibles variaciones en los ángulos de emisión e incidencia del flujo, implica notables deformaciones geométricas en las imágenes radar. Si además consideramos que la señal de retorno no sólo depende del coeficiente de retrodispersión del objeto, sino también de su distancia a la antena, puede enmarcarse la complejidad en la interpretación de estas imágenes.

En primer lugar, conviene considerar que la resolución espacial es distinta en la dirección paralela a la trayectoria (acimut) y perpendicular (distancia) (Lewis *et al.*, 1998). En el primer caso, la mínima distancia en el terreno entre dos objetos que se diferencien en la imagen depende, como hemos visto, de la anchura horizontal del haz emitido (ϕ) y de la distancia entre la antena y la superficie (h). La anchura horizontal también puede estimarse en función de la longitud de la antena, L_a (fig. 3.17):



$$r_a = \frac{d\lambda}{L_a} \qquad [3.2]$$

Aunque en un sistema de abertura sintética la longitud de la antena se incrementa artificialmente, ya que se genera a partir de registrar la señal en dos momentos a lo largo de la trayectoria, la resolución en acimut sigue dependiendo de la distancia al objeto observado. En consecuencia, puesto que la distancia entre objeto y antena cambia desde el extremo más cercano a la traza al más lejano, también cambia la resolución efectiva del píxel en una misma línea de observación. La homogeneización del tamaño precisa, en consecuencia, de correcciones posteriores.

Por su parte, la resolución en profundidad depende de la duración de los pulsos emitidos. Para que el sistema pueda discriminar entre dos objetos, su distancia en el terreno ha de ser superior a la mitad de la longitud del pulso (la mitad porque el pulso tiene que enviarse y regresar). Además hay que considerar que la distancia aparente al radar entre los objetos depende del ángulo de incidencia (θ). Para aumentar la longitud del pulso es preciso disminuir la frecuencia, lo que implica que haya mayor probabilidad de ruido. Esta paradoja se soluciona modulando la frecuencia de los pulsos emitidos y recibidos. En resumen, la resolución en profundidad viene marcada por (fig. 3.18):

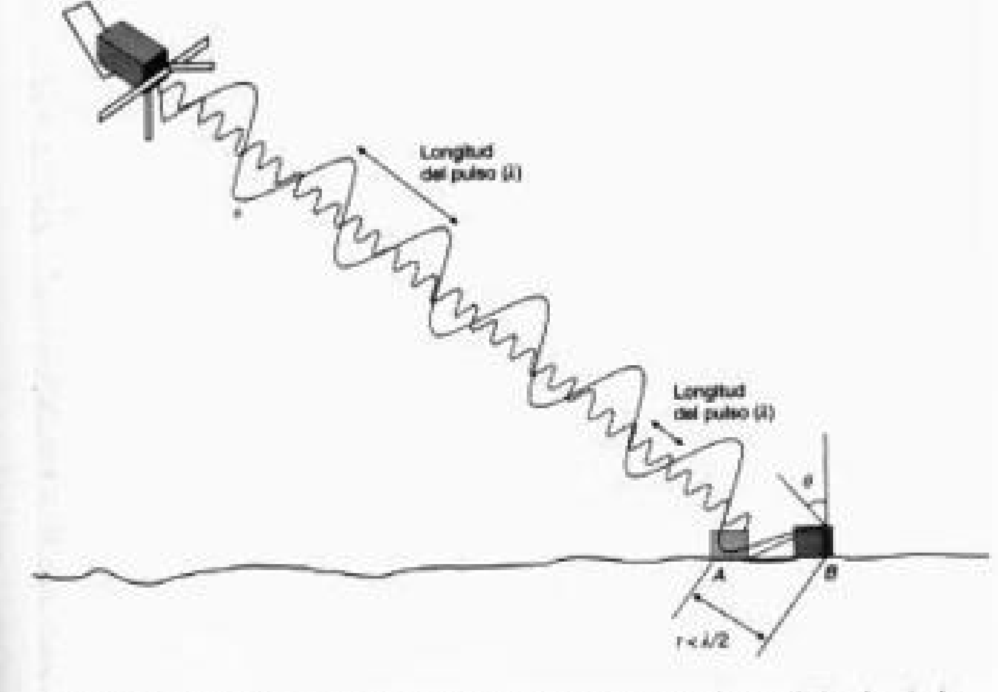


FIG. 3.18. *Resolución en profundidad de un sistema radar: cuando se trabaja a longitudes de onda más largas, los objetos cercanos tienden a mezclarse en la señal retrodispersada.* (Cortesía: A. Kyun.)

$$r_r = \frac{c}{2B \text{ sen } \theta} \qquad [3.3]$$

donde c refiere a la velocidad de la luz, B al ancho de banda y θ al ángulo de incidencia de la onda.

En la geometría de adquisición de imágenes radar tiene una gran influencia el relieve, que modifica el ángulo local de incidencia, además de transformar la superficie real en superficie proyectada sobre la imagen (fig. 3.19). Si la pendiente es menor que el ángulo de incidencia, la imagen ofrece las distancias reales como acortadas. De ahí que las vertientes orientadas hacia la antena aparezcan como inclinadas hacia la dirección de la antena. Otro problema relacionado con el relieve es el efecto de solapamiento inverso *(layover)*, que se produce cuando el relieve modifica la posición con la que aparecen dos objetos en la imagen, a consecuencia de que sus ecos lleguen a la antena en forma inversa a su posición respecto a la trayectoria. Estos factores pueden corregirse, posteriormente, si está disponible un modelo digital del terreno de suficiente fiabilidad. Más complicado resulta corregir el efecto del relieve cuando deja en sombra las vertientes opuestas a la dirección de observación. Este fenómeno, que depende de la altitud del terreno y del ángulo de incidencia, implica perder la información de esas

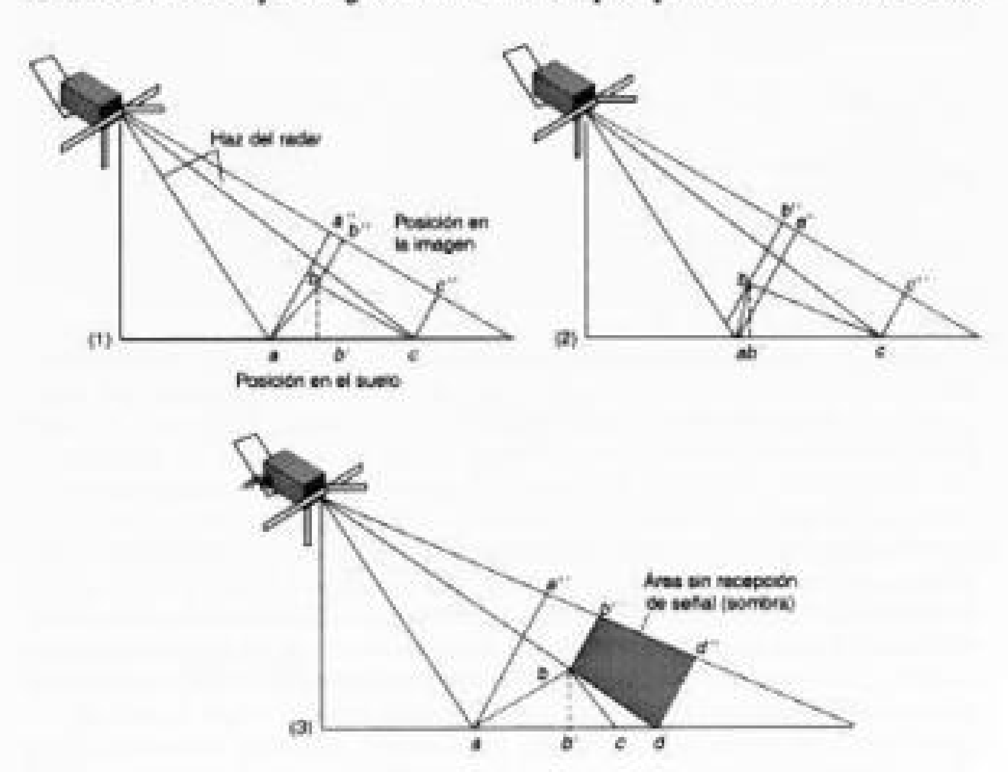


FIG. 3.19. *Efectos del relieve sobre la imagen radar: (1) las distancias se acortan cuando el relieve es muy pronunciado; (2) si el relieve es extremo los objetos pueden aparecer en orden inverso al que realmente ocupan: (3) con ángulos de incidencia bajos, parte del área queda a la sombra del radar.* (Cortesía: Iksu A. Kyun.)

laderas, aunque puede recomponerse si el satélite está diseñado para pasar por el mismo lugar con dos ángulos distintos (pasada ascendente y descendente), como ocurre con el europeo ERS.

En la figura 3.20 aparecen dos imágenes adquiridas por el radar de abertura sintética del ERS-1 con seis días de diferencia. El área corresponde al inicio de la Sierra

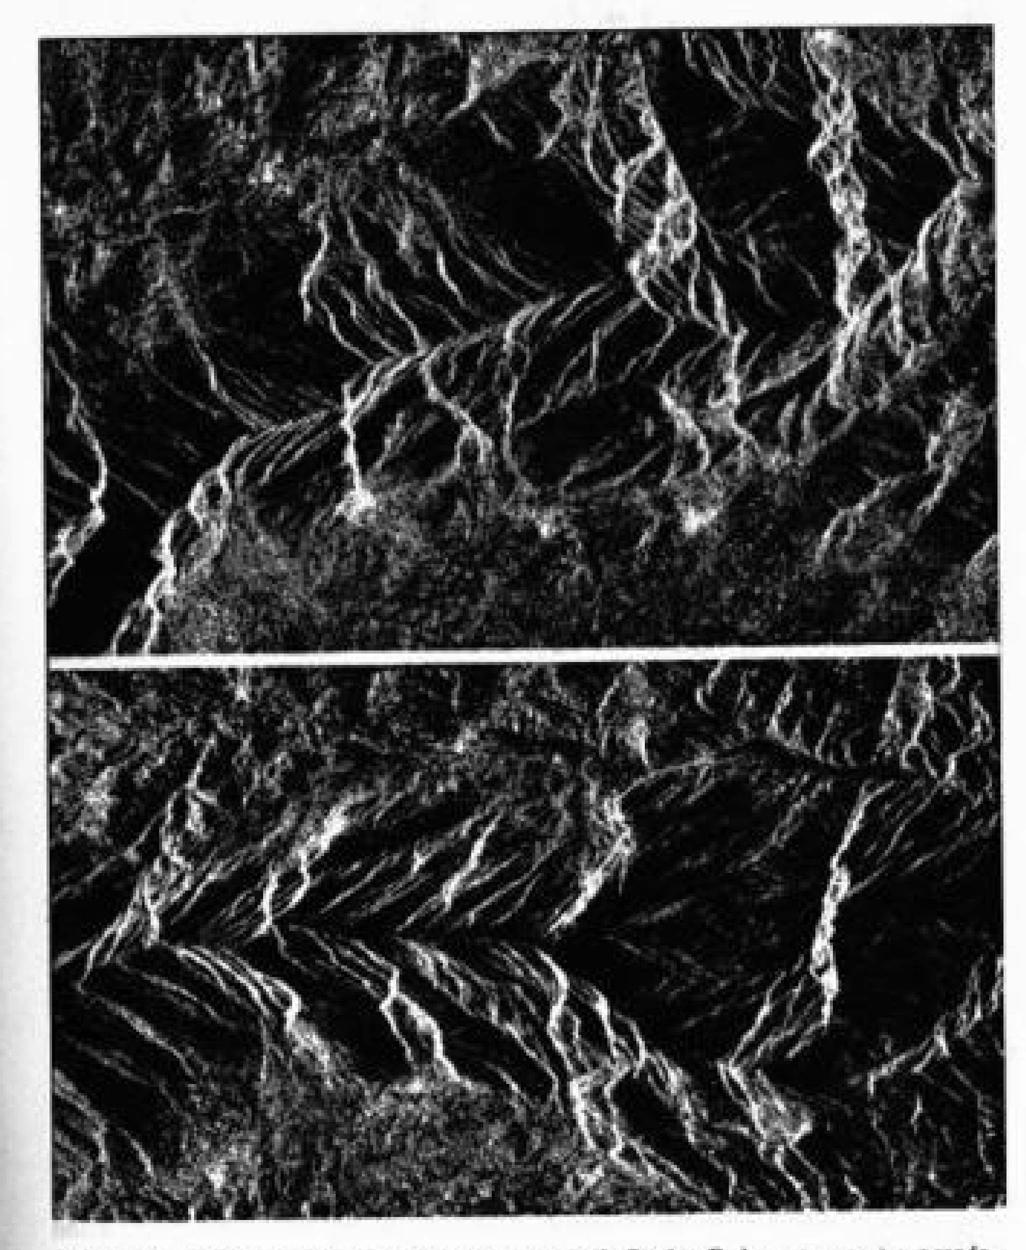


FIG. 3.20. *Imágenes SAR del ERS-1 sobre la Sierra de Gredos. En la parte superior, pasada descendente (23 de abril de 1993); en la inferior, pasada ascendente (29 de abril de 1993).*

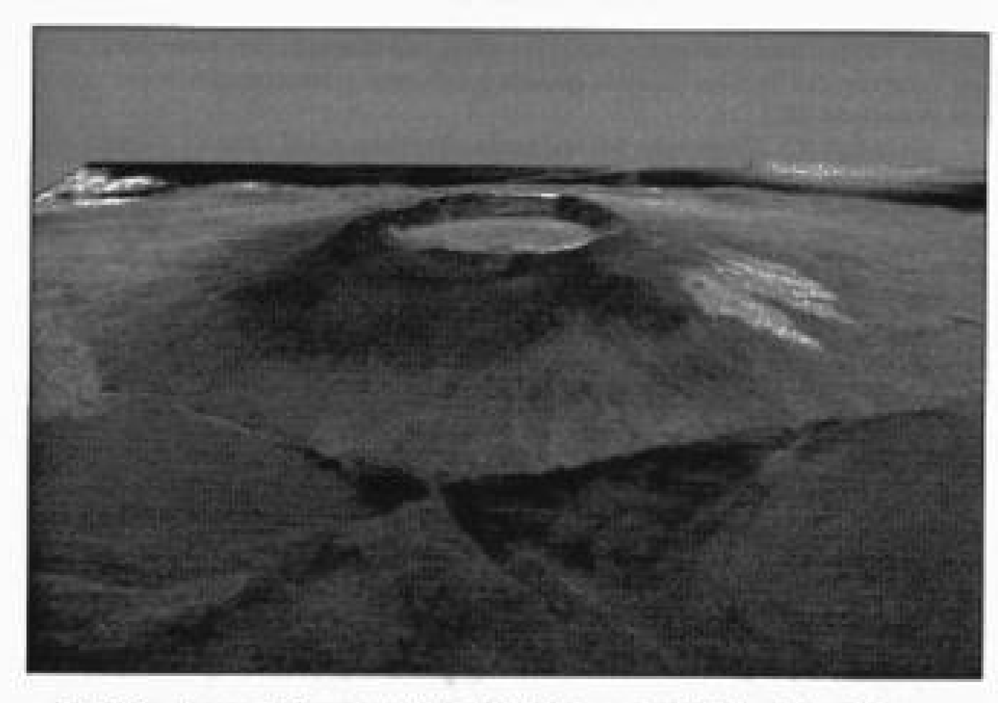


FIG. 3.21. *Imagen tridimensional de la isla Isabela, en el archipiélago de las Galápagos (Ecuador), construida a partir de una imagen del SIR-C (banda X, polarización vertical semejante) y un modelo digital del terreno* (Cortesía: *Jet Propulsión Laboratory.*)

de Gredos, entre las localidades del Tiemblo y Mijares. Al tratarse de un sector con fuertes contrastes topográficos, se observa una notable discrepancia geométrica entre las dos imágenes, que fueron adquiridas en la pasada descendente y ascendente del satélite. Puede observarse cómo el relieve se «inclina» hacia la dirección de la trayectoria.

Pese a sus problemas, el radar de abertura sintética ha sido uno de los sensores de mayor desarrollo en las últimas décadas, a consecuencia de su gran versatilidad de observación, ya que es independiente de las condiciones atmosféricas y de la iluminación solar. Sus posibilidades para el análisis de la vegetación son amplias, complementando la observación de los sensores ópticos. Entre las principales aplicaciones cabe citar la cartografía de la cobertura del suelo (basada en la rugosidad), la detección de alteraciones producidas por incendios o talas, la estimación de algunos atributos forestales (alturas promedio, área basal, biomasa, volumen maderero) y el seguimiento de la regeneración vegetal tras un evento catastrófico (Dobson, 2000).

Naturalmente, estos parámetros requieren radares algo más avanzados que los actualmente disponibles, por ejemplo con capacidad de observación multiangular, multifrecuencia y multipolarización. Hasta el momento, los equipos disponibles han trabajado normalmente en una sola frecuencia, un solo ángulo y un solo nivel de polarización. Éste es el caso de los satélites SEASAT, activo en 1978 para investigación oceanográfica, ERS, Almaz, JERS-1 y RADARSAT (éste puede cambiar la orientación de la antena), así como de las primeras misiones del SIR (fig. 3.21). Sólo en la úl-

tima misión del radar del *Space Shuttle* se incorporó simultáneamente la capacidad multi-frecuencia y multiángulo (experimento SIR-C), que resultó de gran interés para el análisis de cubiertas forestales (Castel *et al.*, 2000). El SAR avanzado del satélite Envisat permitirá en un futuro inmediato extender estas perspectivas.

La figura 4* recoge una magnífica imagen de la Isla de Tenerife adquirida por el SIR-C el 11 de octubre de 1994. La imagen ofrece una composición en color de la banda *L* (polarización HH) en rojo, la banda *L* (polarización HV) en verde, y la banda *C* (HV) en azul. Se observan magníficamente los principales rasgos geomorfógicos de la isla. Junto al Teide se observan distintos flujos de lava en tonos de gris.

Además del radar de imágenes, algunos de estos satélites incorporan otros equipos activos de micro-ondas, como el altímetro, que mide con mucha fidelidad la distancia entre el satélite y la superficie marina (Robin, 1998, p. 37 y ss.), o el dispersómetro de vientos, que mide los campos de vientos (dirección y velocidad) sobre el océano.

También conviene considerar el futuro prometedor de las técnicas de interferometría, que permiten generar modelos digitales del terreno de gran precisión a partir de estudiar la diferencia de fase en el pulso radar para dos adquisiciones casi simultáneas (Madsen y Zebker, 1998; Quegan, 1995). El principio es sencillo, aunque la modelización de la señal sea complicada: se trata de analizar las diferencias en la fase de la señal de retorno entre dos pulsos próximos en el tiempo. Estas diferencias se producen como consecuencia de la variación en altura sobre el terreno, o de movimientos de la superficie. Las diferencias de fase permiten analizar variaciones de tamaño inferior a la longitud de onda retro-dispersada (para el radar del ERS, eso implica longitudes de pocos centímetros). El problema estriba en que esas diferencias de fase requieren un perfecto ajuste entre imágenes, por lo que las adquisiciones tienen que ser prácticamente simultáneas, o al menos que no haya cambios perceptibles entre las dos observaciones. En zonas semiáridas se han podido obtener pares interferométricos con imágenes adquiridas hasta con varios meses de desfase (Massonet *et al.*, 1993), mientras en áreas de mayor densidad vegetal, incluso cambios en la intensidad del viento pueden hacer perder la coherencia entre imágenes.

A partir del lanzamiento del ERS-2 se llevaron a cabo las primeras experiencias interferométricas, poniendo en tándem los dos satélites ERS disponibles para adquirir imágenes en un intervalo muy corto de tiempo. Sin embargo, la disponibilidad de pares interferométricos es escasa. Lo ideal sería una adquisición simultánea, como la llevada a cabo por el *Shuttle Radar Topography Mission* (SRTM), embarcada en la misión STS-99 del *Space Shuttle* en febrero de 2000, que incorporó dos radares, separados unos 60 m gracias a un mástil instalado en el transbordador espacial (www.jpl.nasa.gov/srtm/ mission.html).

Además de la cartografía topográfica, la interferometría se ha utilizado con gran eficacia en la detección y modelado de movimientos sísmicos (D'Errico *et al.*, 1995; Massonet *et al.*, 1995), o producidos por volcanes (Massonet *et al.*, 1995) y glaciares (Pattillo y Pezoa, 2000), lográndose ajustes muy precisos con modelos geológicos y matemáticos más convencionales (fig. 3.22).

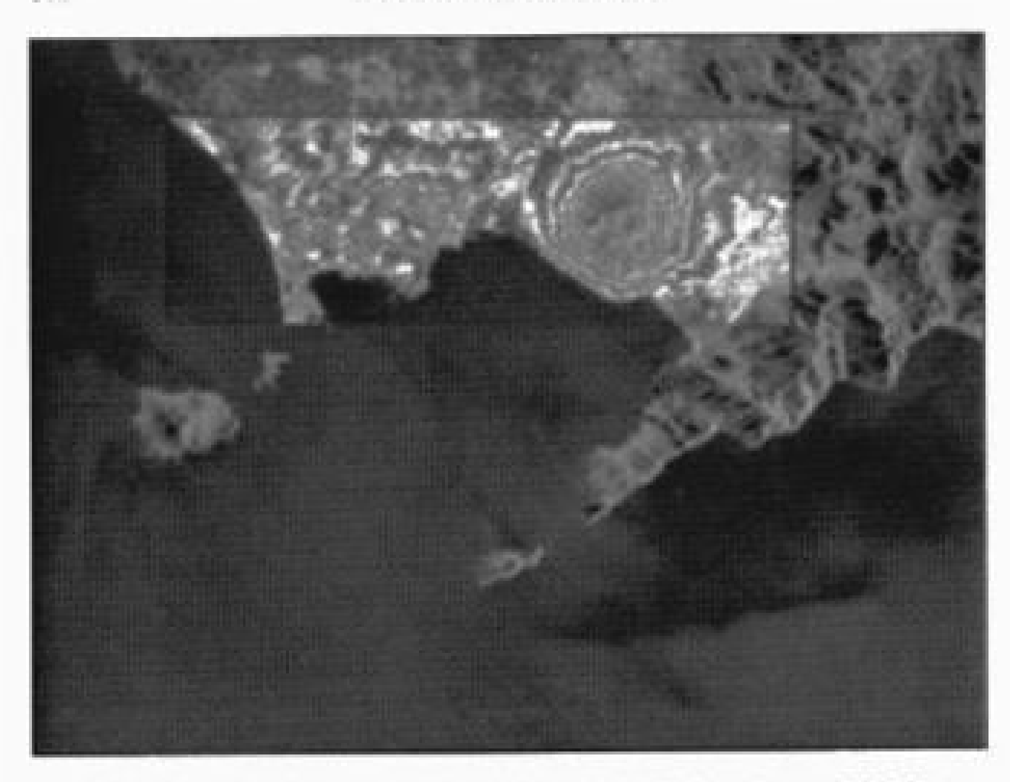


FIG. 3.22. *Imagen de la bahía de Nápoles obtenida fundiendo una imagen ERS-SAR convencional y otra derivada por interferometría, que permite observar la topografía del área* (Cortesía: ESA.)

4.2. LIDAR

El lidar *(Light Detection and Ranging)* es un sensor activo que emite pulsos de luz polarizada entre el ultravioleta y el infrarrojo cercano (Dubayah y Drake, 2000; Kobayashi, 1987; Measures, 1984). Se trata de un láser que emise pulsos muy cortos de una señal modulada en el visible o infrarrojo cercano. Esta señal interacciona con las partículas atmosféricas o el suelo, causando su dispersión en función del tipo de elemento encontrado. La energía de retorno se recoge por un telescopio, que a su vez la transmite a través de un filtro óptico a un foto-detector. Esta señal eléctrica es grabada y posteriormente almacenada en un ordenador. En función del tiempo y la intensidad de la señal de retorno puede deducirse una información muy significativa sobre el tipo de cubierta presente en la zona de estudio.

Existen distintos sistemas lidar, de acuerdo a los principales tipos de dispersión: de Mie, Rayleigh y Raman, de resonancia, de absorción diferencial, y de fluorescencia inducida (Kobayashi, 1987). Cada uno de estos tipos se orienta a aplicaciones específicas. Hasta hace pocos años, los más utilizados se dirigían a explorar las condiciones atmosféricas: detección de aerosoles y partículas contaminantes del aire, medición de la humedad, presión y temperatura del aire, y estimación de la velocidad del viento.

Las experiencias desarrolladas hasta el momento han ofrecido resultados muy interesantes (Huffaker *et al.*, 1984).

En lo que se refiere a la teledetección de cubiertas terrestres, los lidar más utilizados son el de fluorescencia inducida (Chapelle *et al.*, 1984) y el medidor de distancias (altímetro lidar). El primero permite detectar manchas de aceite, algas y contaminantes del agua, condiciones de humedad en la vegetación y contenido de pigmentos. Para los estudios topográficos y cálculos de biomasa se ha utilizado con bastante intensidad en los últimos años el altímetro lidar, diseñado para medir con mucha fiabilidad distancias desde un punto emisor. Típicamente estos equipos emiten un haz láser en el IRC a lo largo de un transecto, con lo que no se les puede catalogar propiamente como sensores de imagen. Ahora bien, los equipos más modernos realizan un barrido de un área a ambos lados de la trayectoria del avión (fig. 3.23*a*), con lo que pueden obtenerse representaciones bidimensionales de los datos. Puesto que las observaciones son puntuales, cada píxel se obtiene extrayendo los pulsos de retorno que se hayan encontrado en la superficie que ocupa. Dependiendo del procesado de los datos el valor de cada píxel corresponderá a la altura máxima obtenida, a un promedio o a un rango de alturas. Si el píxel es suficientemente grande y los pulsos muy densos, algunos se reflejarán en la copa de los árboles, otros en ramas intermedias, otros en el matorral y otros en el suelo (fig. 3.23*b*). Analizando las diferencias entre las distancias registradas podrá reconstruirse la estructura

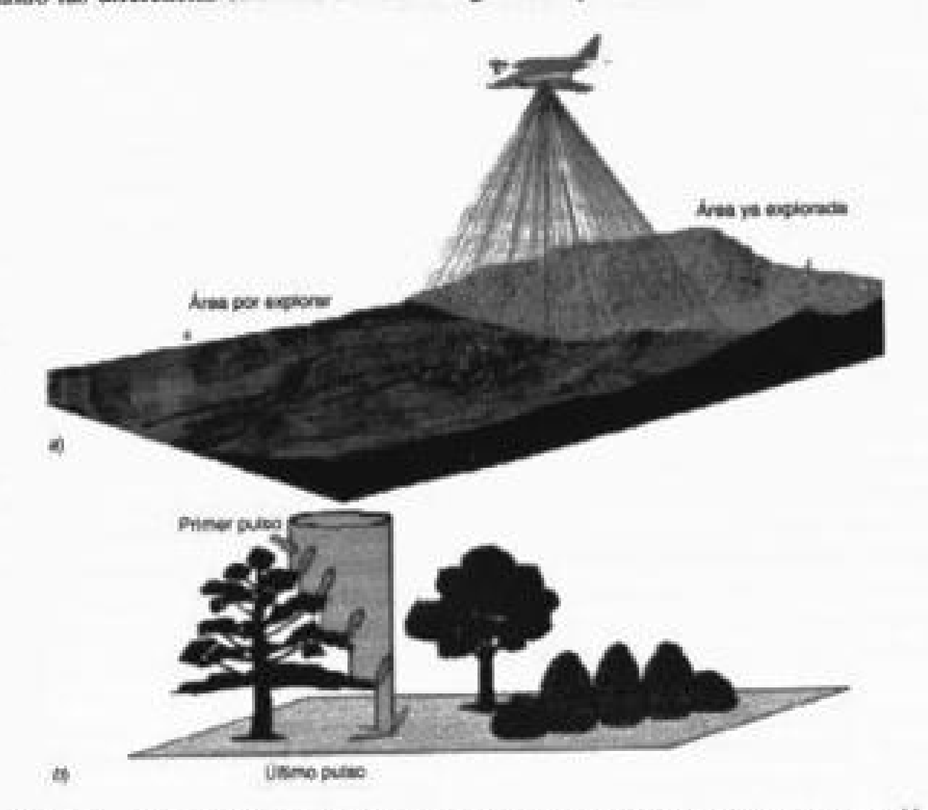


FIG. 3.23. *Principio de funcionamiento del explorador lidar de imagen* (a), *y reconstrucción de las señales de retorno* (b). (Adaptado de www.toposys.com)

vertical de la masa forestal que se esté estudiando (Dubayah y Drake, 2000; Lefsky *et al.*, 1999). Hasta el momento la mayor parte de estas observaciones se han realizado desde avión,[4] pero se está estudiando una misión espacial específica para este sensor: *Vegetation Canopy Lidar* (VCL), inicialmente prevista para 1999, pero finalmente aplazada.

En definitiva, el lidar supone un sensor de gran potencialidad para estudios topográficos y de biomasa vegetal, al facilitar información tridimensional muy precisa (fig. 2*), que puede complementar notoriamente la recogida en otras bandas del espectro. Su principal problema radica en la dependencia, al igual que las otras longitudes de onda ópticas, de las condiciones atmosféricas, así como a requerir un consumo de energía bastante elevado para su funcionamiento en de una plataforma espacial (Cristóbal Martín, comunicación personal).

Aunque no se trata de un equipo activo, sino pasivo, conviene citar en este epígrafe a los satélites LAGEOS *(Laser Geodynamics Satellite)*, lanzados en 1976 y 1992, que incluyen reflectores láser para obtener, con precisión de 1cm, la posición del punto terrestre que esté emitiendo hacia él un haz de láser. Su aplicación más directa es el estudio de la deriva continental. En el segundo satélite colabora muy activamente Italia y está más centrado en la medición de la actividad tectónica en el Mediterráneo (Kramer, 1994).

5. Plataformas de teledetección espacial

Concluimos este capítulo repasando las características de los proyectos más interesantes de teledetección desde el espacio. Bajo la óptica de quien pretende obtener información temática de una imagen, este comentario puede ser útil en la medida en que ofrezca un panorama de la información actualmente disponible.[5]

Antes de iniciar este comentario conviene establecer una clasificación elemental de los tipos de plataforma disponibles en función de su órbita; así distinguimos los denominados geosíncronos y heliosíncronos. Los primeros, que también se denominan geoestacionarios, están colocados en órbitas muy alejadas, lo que les permite sincronizarse al movimiento de rotación de la Tierra, y observar siempre la misma zona (figura 3.24). Además, al contar con un campo amplio de visión pueden observar, en una sola imagen, el disco completo de la Tierra que sea visible desde la longitud a que se encuentren. Éste es el caso de los satélites Meteosat, GOMS, Insat o GOES, situados a unos 36.000 km sobre el Ecuador, a la longitud más apropiada para el área que pretenden observar. El Meteosat se sitúa sobre el meridiano 0° (para adquirir imágenes de Europa), mientras los GOES lo hacen en los meridianos 70° y 140° W, enfocados hacia la costa Este y Oeste, respectivamente, de EE. UU. Al estar siempre situados sobre la misma posición relativa a la Tierra, los satélites geoestacionarios proporcionan la mejor resolución temporal posible.

4. El artículo de Baltsavias (1999) incluye una amplia selección de recursos relacionados con esta tecnología.
5. Un análisis exhaustivo de las características técnicas de las misiones espaciales de teledetección puede revisarse en Kramer (1994) y Morain y Budge (1996), aunque no incluyen lógicamente los sensores más recientes.

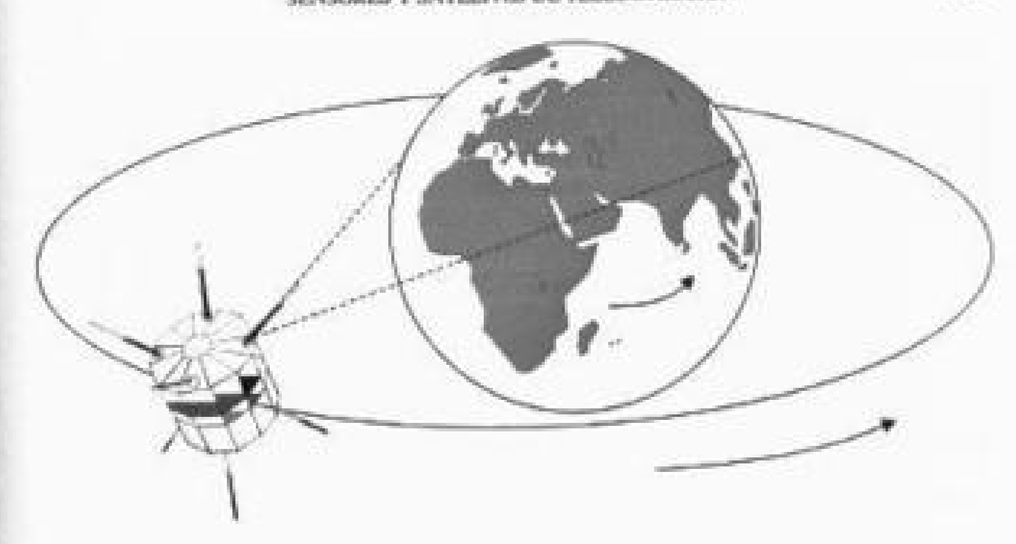


FIG. 3.24. *Esquema de una órbita geosíncrona.*

Por contraposición a éstos, se habla de plataformas *«móviles»*, como aquellas que observan sistemáticamente distintas zonas del planeta. Aunque la órbita puede ser elíptica, lo normal es que sea circular, a fin de mantener en lo posible la misma altura de observación para que las imágenes obtenidas sean comparables. Estas órbitas suelen ser polares (es decir, el plano de la órbita del satélite es aproximadamente perpendicular al plano del Ecuador terrestre), con el propósito de aprovechar el movimiento de rotación del planeta a fin de que la plataforma se sitúe sobre un mismo punto cada cierto tiempo: como la Tierra rota de Oeste a Este, y la plataforma orbita de Norte a Sur de manera constante, ésta podrá observar el mismo punto de la Tierra transcurrido un cierto tiempo, que dependerá de la velocidad y la altura de la órbita. Habitualmente, tanto la altura como la velocidad de la plataforma se calculan para que ésta observe cada porción de la Tierra a una hora solar fija (las órbitas que persiguen este objetivo se denominan heliosíncronas, figura 3.25).

La elección de la órbita que ocupa una plataforma viene determinada por las características de la misión del satélite: si se pretende tomar datos de una gran superficie en una sola imagen a fin de observar fenómenos globales y muy dinámicos (como la nubosidad) se trabaja con satélites geoestacionarios —o, en todo caso, con polares que cuenten con un amplio campo de visión—; por el contrario, si se pretende un mayor detalle en la observación se utilizan plataformas de órbitas más bajas.

5.1. El programa Landsat

Gracias a los brillantes resultados que proporcionaron las primeras fotografías espaciales, la agencia espacial norteamericana diseñó a fines de la década de los sesenta el primer proyecto dedicado exclusivamente a la observación de los recursos terrestres.

Fruto de estos trabajos fue la puesta en órbita del primer satélite de la serie

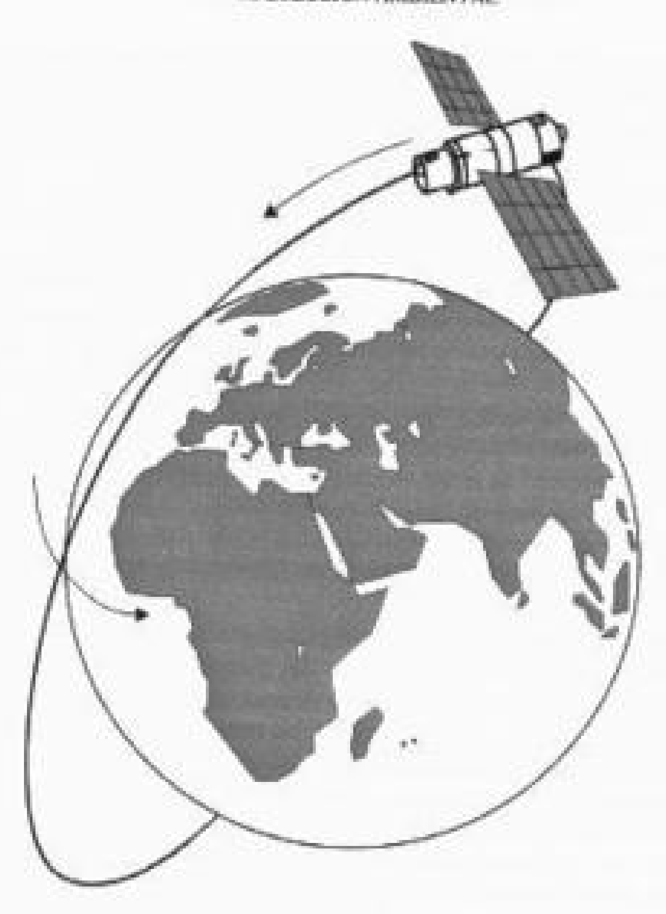


FIG. 3.25. *Esquema de una órbita polar.*

ERTS (*Earth Resource Technollogy Satellite*) el 23 de julio de 1972. Esta familia de satélites, denominada Landsat a partir del segundo lanzamiento, en 1975, ha constituido, sin duda, el proyecto más fructífero de teledetección espacial desarrollado hasta el momento. La buena resolución de sus sensores, el carácter global y periódico de la observación que realizan y su buena comercialización, explican su profuso empleo por expertos de muy variados campos en todo el mundo. Sólo hasta 1980, la cobertura territorial proporcionada por los diversos satélites de la serie se cifraba en unos 32.000 millones de km^2, alcanzando la cifra de 385.000 las imágenes adquiridas por estaciones estadounidenses, y 560.000 las recibidas por estaciones foráneas (Brasil, Canadá, China, Italia, Suecia, Irán, Japón, India, Argentina, Sudáfrica y Australia: Colwell, 1983, pp. 517-570). Estos datos bastan por sí solos para valorar la importancia de este proyecto espacial, y justifican un detallado análisis en el marco de esta obra.

5.1.1. *Características orbitales*

Los primeros tres satélites Landsat tenían un aspecto muy similar al del Nimbus, en forma de mariposa por la disposición de los paneles solares (fig. 3.26). Sus dimensiones eran de 3 m de altura por 1,5 m de diámetro, que se tornaban en 4 m cuando se extendían dichos paneles. El peso total del sistema se aproximaba a los 960 kg. Su ór-

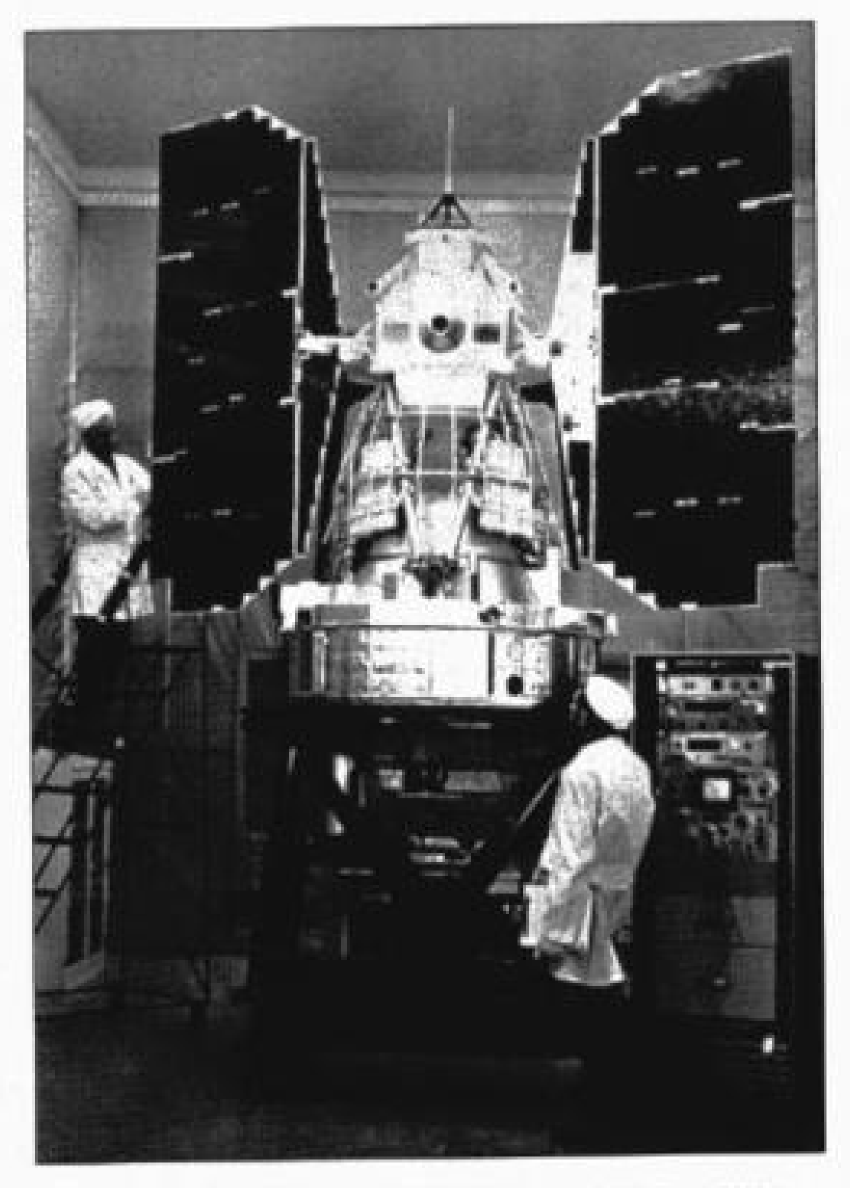


FIG. 3.26. *Configuración de los satélites Landsat-1 a 3.* (Short, 2000.)



FIG. 3.27. *Configuración de los Landsat-4 y 5.*

bita era heliosíncrona, polar, ligeramente inclinada (99,1 grados). Con una altura orbital media de 917 km, circundaba la tierra cada 103 minutos, con lo que realizaba 14 órbitas diarias para volver sobre la misma porción de la superficie terrestre a los 18 días, y a la misma hora local (entre las 9,30 y las 10,30 a.m. según latitudes). Con el fin de reducir al máximo las alteraciones en las condiciones de observación se dotó a los satélites de un sistema de estabilización según tres ejes, orientados hacia la superficie terrestre y la vertical del punto nadir. Las correcciones en la órbita, por tanto, se hacían desde las estaciones terrestres, lo que confería una gran estabilidad en la toma de datos.

Los dos siguientes, el Landsat-4 y 5, modificaron su fisonomía (fig. 3.27) y sus características orbitales. La altura de vuelo se reduce de 917 a 705 km, aunque se mejora el ciclo de recubrimiento, de 18 a 16 días en nuestras latitudes, gracias a un menor período orbital (98,9 minutos). El momento de adquisición, sin embargo, se mantiene en torno a las 9,45 a.m., hora solar en nuestras latitudes.

Los Landsat-6 y 7 volvieron a cambiar la forma del satélite (fig. 3.28), aunque se mantienen las características orbitales de sus predecesores. El Landsat-6 se perdió

poco después del lanzamiento, por lo que sólo nos referiremos al último, lanzado en 1999. Se sitúa a una altura de 705 km, en órbita cuasi-polar y heliosíncrona a una inclinación de 98,2°, manteniendo un área observada de 183 km y un período de revisita de 16 días.

5.1.2. *Instrumentos de observación*

MSS

Los tres primeros Landsat incorporaban un equipo de barrido multi-espectral denominado MSS *(Multispectral Scanner)* y un conjunto de tres cámaras de vídeo (RBV, *Return Beam Vidicon*). Los Landsat-4 y 5 eliminaron las cámaras RBV y las sustituyen por un nuevo explorador de barrido, denominado TM *(Thematic Mapper)* que proporcionaba mayor resolución espacial y espectral que el previo MSS. Para asegurar la continuidad en la serie de datos, también se mantuvo el MSS en los dos Landsat-4 y 5, con similares características a los anteriores satélites.

En definitiva, el MSS ha sido el sensor más empleado hasta el momento, gracias a la larga serie de imágenes disponibles, desde 1972 hasta fechas muy recientes.

El sensor MSS era un equipo de barrido óptico-electrónico con un campo total de visión de 11,56°, lo que, a la altura orbital del satélite, le permitía explorar una franja de terreno de 185 km, divididos a ambos lados de la vertical de la traza.

En el diseño del sensor MSS se tuvieron en cuenta las medidas espectrales de la-

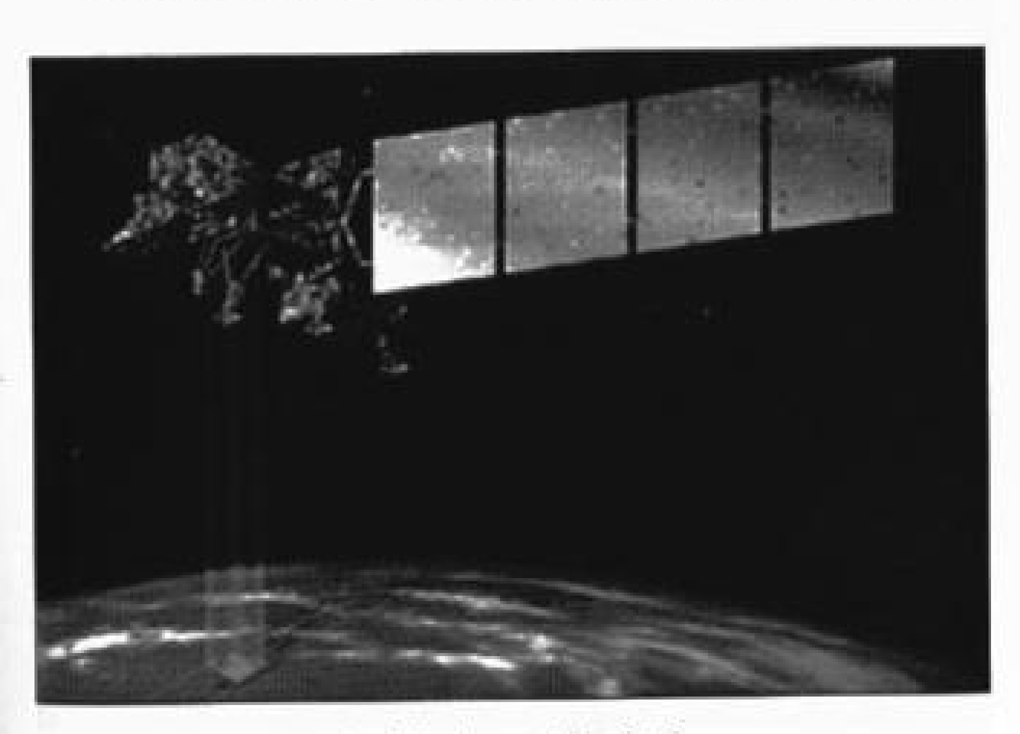


FIG. 3.28. *Aspecto del Landsat-7.*

TABLA 3.1. *Sensores a bordo del programa Landsat*

MSS[1]		*RBV*		*TM*[2]		*ETM+*[3]	
4	0,5-0,6 μm	1[4]	0,475-0,575 μm	1	0,45-0,52 μm	1	0,45-0,52 μm
5	0,6-0,7 μm	2[4]	0,580-0,680 μm	2	0,52-0,60 μm	2	0,52-0,60 μm
6	0,7-0,8 μm	3[4]	0,690-0,830 μm	3	0,63-0,69 μm	3	0,63-0,69 μm
7	0,8-0,1,1 μm	1[5]	0,505-0,750 μm	4	0,76-0,90 μm	4	0,76-0,90 μm
8[5]	10,4-12,6 μm			5	1,55-1,75 μm	5	1,55-1,75 μm
				6	10,40-12,50 μm	6	10,40-12,55 μm
				7	2,08-2,35 μm	7	2,08-2,35 μm
						8	0,52-0,90 μm
Resolución espacial							
4-7	79 m	1-3	80 m	1-5, 7	30 m	1-5, 7	30 m
						6	120 m/60[3] m
8	240 m	1	40 m	6	120 m	8	15 m

1. Sólo en los Landsat-1 a 5.
2. Sólo en los Landsat-4 y 5.
3. Sólo en el Landsat-7.
4. Sólo en los Landsat-1 y 2.
5. Sólo en el Landsat-3.

boratorio, de tal forma que las 4 bandas finalmente incluidas pretendían realzar la aplicación de este sensor a la detección de masas vegetales, recursos hídricos y mineros (tabla 3.1).[6] Las bandas visibles (4 y 5) tienen mejores disposiciones para la detección de aspectos antrópicos, como áreas urbanas o vías de comunicación, a la vez que proporcionan una interesante información sobre la calidad del agua. Las dos bandas en el infrarrojo cercano (6 y 7) pretenden registrar parámetros vitales en la actividad de las plantas, además de ser especialmente sensibles a la humedad.

Con objeto de acoplar la secuencia de barrido a la velocidad del satélite, el sensor MSS registraba seis líneas simultáneamente con cada oscilación del espejo. La radiancia recibida por el sistema focal se transmitía a un sistema óptico que la descomponía en cuatro bandas, y la enviaba a distintos detectores. Por tanto, el MSS disponía de 24 detectores (6 líneas × 4 bandas), compuestos por foto-diodos de silicio (banda 7), y por tubos foto-multiplicadores (bandas 4 a 6). En el caso del Landsat-3 se añadió una banda térmica (banda 8), registrada por detectores de mercurio-cadmio-telurio.

Las señales analógicas que producían los detectores eran amplificadas, convertidas a formato digital y enviadas directamente a las estaciones receptoras, desde donde se iniciaba la distribución de las imágenes. Cuando el satélite no se encontraba en el área de influencia de alguna antena terrestre, los primeros Landsat incorporaban un sistema de grabación a bordo denominada WBVTR *(Wide Band Video Tape Recorders)*, que permitió adquirir imágenes de estas áreas. En los últimos satélites, el flujo de información es tan grande que requieren estar conectados a una red de satélites de comunicación o situarse sobre al área abarcada por una de las antenas

6. A lo largo del capítulo se incluirán tablas con las características técnicas de los principales sensores comentados. Aquellos que no se recogen en el texto, con objeto de simplificar la exposición, aparecen citados en el CD-ROM anexo a esta obra.

de recepción. Esta red de antenas receptoras hoy cubren prácticamente el conjunto de la superficie terrestre. En el caso de España, la antena receptora se encuentra en Fucino, muy próxima a Roma, para el territorio peninsular, y en Maspalomas para la cobertura de las islas Canarias y África occidental. Para América Latina, están activas en este momento las estaciones de Córdoba (Argentina), Cotopaxi (Ecuador) y Cuiaba (Brasil), mientras la de Norman (EE. UU.) cubre México y parte de América Central y Antillas.

Una escena adquirida por el sensor MSS comprendía 2.340 líneas de barrido y 3.240 columnas por línea. Cada píxel correspondía a una superficie real de 79 m de lado (0,62 ha), si bien en la transformación digital se le asignaba un formato nominal de 57 × 79 m, lo que explicaba la disimetría final entre el número de líneas y de columnas en la imagen. La radiancia recibida para esa parcela del terreno se transformaba a un valor entero para su almacenamiento en CCT. Ese valor, en los primeros MSS, estaba comprendido entre 0 y 127 para las bandas 4 a 6, y entre 0 y 63 para la banda 7. Los posteriores MSS codificaban las cuatro bandas entre 0 y 255, la medida estándar en un equipo de tratamiento digital.

Sistema de vídeo

Los dos primeros satélites Landsat incorporaron un sistema de tres cámaras RBV, cada una de las cuales registraba información en una banda espectral comprendida entre el verde y el IRC (tabla 3.1). Su resolución espacial se cifraba en 80 m, cubriendo la misma porción superficial del sensor MSS.

Este sistema no funcionó adecuadamente en los dos primeros Landsat, por lo que fue sustituido en el tercero por otro. En este caso, el planteamiento se dirigió más a mejorar la resolución espacial que la espectral, por lo que se montaron dos cámaras pancromáticas de mayor resolución operando simultáneamente con el MSS. Estas cámaras cubrían un abanico espectral de 0,505 a 0,705 μm, proporcionando —en cuatro adquisiciones— la misma cobertura del MSS, pero con una resolución aproximada de 40 m. El registro entre ambas permitió utilizar el RBV como auxiliar del MSS, especialmente para mejorar la calidad visual de sus imágenes. Para ello se emplearon diversas técnicas de fusión, como la normalización de las bandas MSS, a partir de la proporcionada por RBV (Short, 1982), o la transformación IHS (cap. 7, apdo. 15).

En el campo de las aplicaciones temáticas, el RBV se ha utilizado en estudios morfológicos (Tricart, 1981) y en cartografía de la cubierta del suelo (King, 1981), si bien, la escasa pervivencia de este sensor ha reducido sensiblemente su rango de aplicaciones.

TM y ETM+

Como antes se indicó, el lanzamiento de los Landsat-4 y 5 supuso un notable impulso del programa Landsat. Su principal aportación consistió en incorporar un nuevo sensor, denominado *Thematic Mapper* (TM), directamente diseñado —como su nombre indica— para la cartografía temática.

Al igual que su predecesor, el MSS, el *Thematic Mapper* es un equipo de barrido

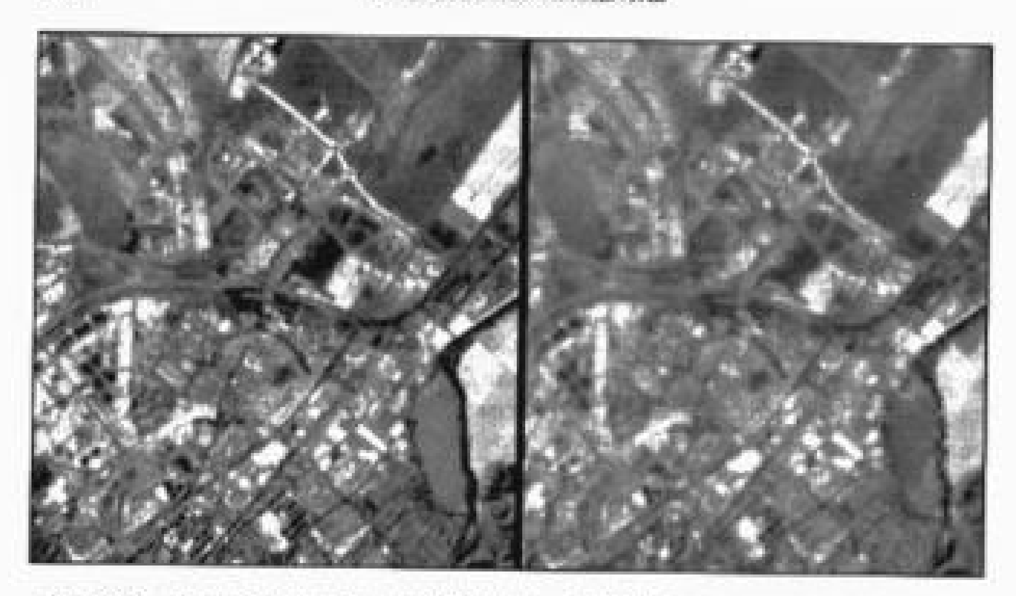


FIG. 3.29. *Imagen pancromática del ETM+ de la ciudad de Alcalá de Henares (Alcalá 99). La mejora en la resolución espacial (15 m) puede observarse por comparación con la imagen de la derecha, que incluye la banda roja de la misma escena (30 m).*

multi-espectral, que emplea una técnica muy similar a la descrita previamente. Sin embargo, las novedades que incorpora permiten considerarlo como perteneciente a una nueva generación de sensores. Frente al MSS, el TM aumenta el número de detectores, de 24 a 100, a la vez que se reduce el IFOV, se aumentan los niveles de codificación y se realiza el barrido en las dos direcciones. Todo ello le permite mejorar la resolución espacial, espectral y radiométrica: de 79 a 30 m, de 4 a 7 bandas, y de 6 a 8 bits. En el TM, cada oscilación del espejo supone 16 líneas de barrido, frente a 6 en el MSS. De esta forma se precisan 16 detectores por banda, salvo la banda térmica que registra una menor resolución (120 m) y sólo requiere cuatro detectores. Este aumento en el número de detectores complica el proceso de calibración, a la par que aumenta el volumen de datos a procesar frente al MSS. Los detectores están formados por tubos de silicio, para las bandas 1 a 4, indio-antimonio para las bandas 5 y 7, y mercurio-cadmio-telurio para la banda 6.

En el último Landsat lanzado hasta el momento (el 7) se ha incorporado un nuevo sensor, el ETM+, que mejora las características del TM, añadiéndole una banda pancromática de 15 m de resolución (fig. 3.29), y aumentando la resolución de la banda térmica a 60 m (con dos niveles de ganancia, por lo que se distribuyen dos bandas térmicas distintas). La inclusión del canal pancromático está siendo de gran utilidad para obtener productos cartográficos de mayor calidad, aplicando técnicas de fusión de datos.

El incremento de la resolución espacial y espectral que ofrecen tanto el TM como el ETM+ ha permitido mejorar notablemente la precisión obtenida en múltiples ámbitos de la cartografía temática, a la vez que ha permitido ampliar el rango de aplicaciones operativas a partir de sensores espaciales. En este sentido, el diseño de estos sensores

pretendió paliar las deficiencias observadas en las imágenes MSS, incorporando información de cuatro bandas del espectro no contempladas en el MSS (azul, dos en el SWIR y una en el IRT), mientras se sustituían las bandas 6 y 7 de ese sensor —ambas en el IRC— por una sola, sin perder información sustancial (tabla 3.1)

Con esa nueva configuración, el TM y ETM+ han aportado una sensible mejora en las aplicaciones terrestres y marinas del sensor MSS: detección de turbidez y contaminantes en el agua (banda azul), exploración minera (SWIR), contenidos de humedad en las plantas y suelo (SWIR), detección de focos de calor (SWIR e IRT), además de mantener las aplicaciones antes señaladas para el sensor MSS.

A la vez, el lanzamiento del Landsat-7 ha llevado consigo una severa reducción de los costes de las imágenes (600 dólares USA para los datos ETM+ brutos), lo que ha implicado la casi desaparición de los pedidos de cuartos de escena o mini-escenas, tan frecuentes para las imágenes TM, lo que supone, como único inconveniente, el aumento del volumen de datos a procesar (las 8 bandas ETM+, incluida la pancromática, suponen unos 400 Mb).

5.1.3. *El futuro del programa Landsat*

La amplitud temática y geográfica de los usuarios del programa Landsat explica el gran interés que la comunidad científica internacional ha brindado a esta familia de satélites. Como antes comentamos, la Administración Reagan impulsó la transferencia del programa Landsat al sector privado en 1984 (O.T.A., 1984). Pocos meses más tarde, en 1985, la compañía EOSAT recibía los derechos para vender productos Landsat por un período de 10 años, con el compromiso de participar en el desarrollo de futuros sensores. Por su parte, el gobierno mantenía la responsabilidad en el control físico de la plataforma (a través de la agencia NOAA, con amplia experiencia en la gestión de los satélites meteorológicos), mientras que se comprometía a colaborar en el desarrollo de los Landsat-6 y 7. Nuevos recortes presupuestarios pusieron en entredicho este compromiso, hasta el punto de llegar a una situación límite, a inicios de 1989, en el que se temió por la continuidad de los propios Landsat-4 y 5, en ese momento en órbita.

Las numerosas presiones de la comunidad científica y profesional, el desarrollo de programas espaciales por parte de otros países, singularmente Francia con su programa SPOT (que llevó a temer por el liderazgo estadounidense en esta línea), el creciente interés por la observación global de los cambios ambientales (al tener ya disponible un amplio archivo histórico de imágenes MSS), y las aportaciones estratégicas de las imágenes Landsat en la guerra del Golfo (1991), llevaron a modificar el rumbo de los acontecimientos, asegurando un marco jurídico estable para el futuro del programa Landsat a través de la *Land Remote Sensing Policy Act* de 1992 (Williamson, 2001). Por esta ley se transfería de nuevo el control del programa Landsat al gobierno federal, en un primer momento al Departamento de Defensa y la NASA, y más tarde al Departamento de Interior (a través del *U.S. Geological Survey*) que se encargaría del archivo y la distribución de los datos, en colaboración con la NASA (encargada del desarrollo del satélite y sensores) y la NOAA (responsable de la operación del satélite y del sistema terrestre). Este acuerdo, forzado también por el fracaso en el lanzamiento del Landsat-6, en 1993, ha permitido poner en órbita con éxito el Landsat-7, seis años más tarde, y garantizar una continuidad en los datos.

Mediante una disposición del año 1994, revisada en 1997 y en 2000, se establecieron las líneas maestras de la política de distribución de datos Landsat, que básicamente cuenta con los siguientes principios: asegurar que los datos brutos estén disponibles a todos los usuarios a precios de coste, sin restricciones y con razonable rapidez; asegurar que los EE. UU. mantienen la propiedad de los datos brutos generados por la plataforma; respaldar el desarrollo de aplicaciones comerciales de los datos; asegurar que las aplicaciones comerciales sólo se realicen por el sector privado; facilitar, en la medida de lo posible, la integración de los sistemas de distribución de datos Landsat con los generados por el programa EOSDIS (Sistema global de observación terrestre), y promover la investigación y el desarrollo de las aplicaciones de la teledetección (http://ldcm.usgs.gov/refdocuments.html). Estas disposiciones han permitido reducir considerablemente los costes de los datos brutos de las imágenes ETM+ (a casi un 10 % del importe de las imágenes TM adquiridas por los Landsat-4 y 5). Lamentablemente, el sensor ETM+ registró un fallo del mecanismo de barrido en mayo de 2003, lo que dificulta notablemente el uso de imágenes de este sensor, mientras el Landsat-5 está al final de su vida útil. En consecuencia, la continuidad de los datos Landsat está en serio compromiso, ya que todavía no se han definido las misiones concretas que la reemplacen.

5.2. El satélite SPOT

Este programa espacial supuso un fuerte impulso a la diversificación de las tecnologías de teledetección, ampliando la oferta a otros países además de EE.UU. El primer satélite SPOT *(Systeme Pour l'Observation de la Terre)* se lanzó en 1986. Desde entonces se han lanzado otros tres satélites en 1990, 1993 y 1998. Todos ellos se han desarrollado en el CNES francés, en colaboración con Bélgica y Suecia. El SPOT orbita a una altitud de unos 822 km, con una inclinación de 98° y un período orbital de 101 min. Cuenta con una órbita heliosíncrona y la duración del ciclo es de 26 días.

Entre las novedades más interesantes de este satélite se contaba la incorporación de dos equipos de exploración por empuje denominados HRV *(Haute Resolution Visible)*. Estos dos sensores permiten obtener imágenes en dos modalidades: pancromático y multibanda (V, R, IRC), con una resolución espacial de 10 y 20 m, respectivamente (tabla 3.2). El área cubierta en cada escena es de 60 km de lado, por lo que estos sensores necesitan incorporar 3.000 detectores en modo multi-espectral y 6.000 en modo pancromático.

Otra importante novedad que incluyó el satélite SPOT era la capacidad del sensor HRV para variar su campo de visión, gracias a un dispositivo móvil instalado en el equipo óptico que facilita observaciones no verticales, de hasta 27° a ambos lados del nadir. Esto le permite observar la misma zona en órbitas sucesivas, reduciendo la frecuencia temporal de las imágenes si es necesario (de 26 días a 2-3 días según las latitudes). Además, con esa misma aptitud, el HRV puede adquirir imágenes estereoscópicas, lo que añade a su potencial temático una clara capacidad topográfica (fig. 3.30). Las experiencias realizadas hasta el momento han permitido obtener modelos digitales del terreno con escalas de hasta 1:50.000, a partir de imágenes SPOT (Toutin y Beaudoin, 1995). En definitiva, la flexibilidad del sistema le facilita adaptar su órbita a las necesidades del usuario (Chevrel *et al.*, 1981; Kayser *et al.*, 1992).

Tabla 3.2. *Sensores a bordo del satélite SPOT*

HRV[1]		*HRVIR*[2]		*Vegetation*[2]	
1	0,50-0,59	1	0,50-0,59	1	0,43-0,47
2	0,61-0,68	2	0,61-0,68	2	0,61-0,68
3	0,79-0,89	3	0,79-0,89	3	0,78-0,89
P	0,51-0,73	4	1,58-1,75	4	1,58-1,75
		P	0,51-0,73		
Resolución espacial					
1-3	20 m	1-3	20 m	1-4	1.000 m
P	10 m	P	5 m		

1. Sólo en los SPOT-1 a 3.
2. Sólo en los SPOT-4 y 5.

Además del sensor HRV, los siguientes satélites SPOT han incorporado dos equipos de apoyo, el DORIS, que proporciona un seguimiento muy preciso de la posición del satélite, y el POAM *(Polar Ozone and Aerosol Measurement)*, incorporado en el SPOT-3, que mide el contenido de ozono, aerosoles, nitrógeno, oxígeno y vapor de agua. Poseía 9 canales comprendidos entre el ultravioleta e infrarrojo cercano (Kramer, 1994).

El lanzamiento del SPOT-4 en 1998 supuso una mejora notable en la carga útil del satélite. El sensor de alta resolución pasó a denominarse HRVIR, incorporando una nueva banda en el SWIR. Además, la orientación de las dos cámaras es ahora independiente, lo que permite tomar simultáneamente imágenes verticales y oblicuas. Se

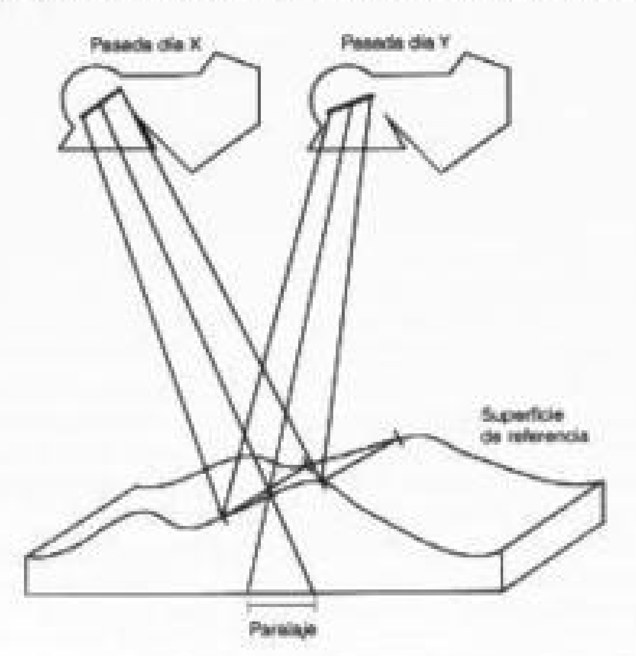


Fig. 3.30. *Sistema de adquisición de imágenes estereoscópicas del satélite SPOT.*



FIG. 3.31. *Imagen* Vegetation *de la península Ibérica adquirida el 8 de septiembre de 1999.*

ha ampliado también la autonomía de grabación. Este satélite también incorpora los equipos DORIS y POAM. Sin embargo, la principal novedad es la inclusión de un nuevo sensor idóneo para estudios globales. Se denomina *Vegetation*, y cuenta con una resolución espacial de 1 km^2, en 4 bandas espectrales (A, R, IRC, SWIR), cubriendo un área de 2.250 km, lo que facilita una adquisición diaria sobre todo el planeta (Eastwood *et al.*, 2000). En cierta medida, las imágenes del *Vegetation* permiten continuar los estudios que se venían haciendo en los años ochenta con imágenes AVHRR del NOAA, que comentaremos en breve, si bien este sensor cuenta con una radiometría más estable y unas condiciones geométricas de adquisición mucho más favorables que las del AVHRR (fig. 3.31).

Al igual que las imágenes del HRVIR, las adquiridas por *Vegetation* se comercializan a través de la empresa Spot-Image, que cuenta con acuerdos con distintas antenas receptoras en casi todo el mundo. Para España y Latinoamérica, los centros de recepción se encuentran, en Maspalomas, Fucino y Toulouse, para el sur de Europa, y Cotopaxi (Ecuador) y Cuiaba (Brasil), para Sur y Centroamérica.

El proyecto se amplió en mayo del 2002 con el lanzamiento del SPOT-5 que incorpora mejoras en la resolución espacial (de 10 a 5 o 2,5 m en el pancromático, y de 20 a 10 m en el multiespectral, salvo el SWIR que sigue con 20 m).

5.3. EL PROGRAMA IRS

La agencia espacial india (NRSA) ha sido bastante activa en los programas de observación de la Tierra, ya desde los años setenta con la serie Bhaskara. Entre los más modernos destacan los cuatro satélites IRS *(Indian Remote Sensing Satellite)*, lanzados hasta el momento (1988, 1994, 1995 y 1997). El objetivo directo de esta misión es mejorar el conocimiento de los recursos naturales de ese gran país asiático, pero sus imágenes se han utilizado en muchas otras aplicaciones.

En el caso del IRS se opta por la tecnología de exploración por barrido, con dos sensores denominados LISS *(Linear Imaging Self Scanning)* que ofrecen una resolución de 72,5 m (LISS-I) si opera una cámara, y 36,25 m (LISS-II) si operan dos. La superficie cubierta en cada escena es de 148 km para el LISS-I, y de 74 km para el LISS-II, con un ciclo de repetición de 22 días. El sensor LISS facilita información sobre cuatro bandas del espectro, comprendidas entre el azul y el IRC para los dos primeros, y entre el rojo y el SWIR para los dos segundos (tabla 3.3), por lo que resulta idóneo para estudios costeros, discriminación de cubiertas vegetales y exploración minera.

En los dos últimos satélites de la serie (el IRS-1C y 1D) se añadió a este sensor otros dos sensores: una cámara pancromática con alta resolución (5,8 m), explorando una zona de 70 km, y un sensor de observación regional, el WIFS, con resolución de 188 m y un área cubierta de 810 km.

Las imágenes IRS se comercializan a través de diversas empresas privadas en Europa (DLR-GAF) y EE. UU. *(Space Imaging)*. Al tratarse del sensor con mayor resolución espacial disponible hasta hace muy poco tiempo, las imágenes pancromáticas del IRS-1C y D se han utilizado extensivamente en temas urbanos y de inventario forestal. Pese a su baja sensibilidad radiométrica (las imágenes se codifican en 6 bits), todavía resulta una alternativa razonable en tareas de interpretación visual (fig. 3.32), al menos mientras sigan manteniéndose los altos costes de los satélites comerciales de alta resolución.

Además de este programa, la agencia NRSA tiene un satélite oceanográfico, denominado IRS-P4 (Oceansat) que se lanzó en 1999. Cuenta con un sensor óptico de 8 canales y resolución de 360 × 236 m, y un radiómetro de micro-ondas con 4 bandas y resolución entre 40 y 10 km.

TABLA 3.3. *Sensores a bordo del satélite IRS*

LISS-I[1]		LISS-II[2]		WiFS[2]	
1	0,45-0,52	1	0,52-0,59	1	0,62-0,68
2	0,52-0,59	2	0,62-0,68	2	0,77-0,86
3	0,62-0,68	3	0,77-0,86		
P	0,77-0,86	4	1,55-1,70		
		P[2]	0,5-0,75		
Resolución espacial					
1-4	76,5 m/ 32.25	1-4	23 m	1-2	188 m
		P	5,8 m		

1 Sólo en los IRS-1A y 1B
2 Sólo en los IRS-1C y 1D

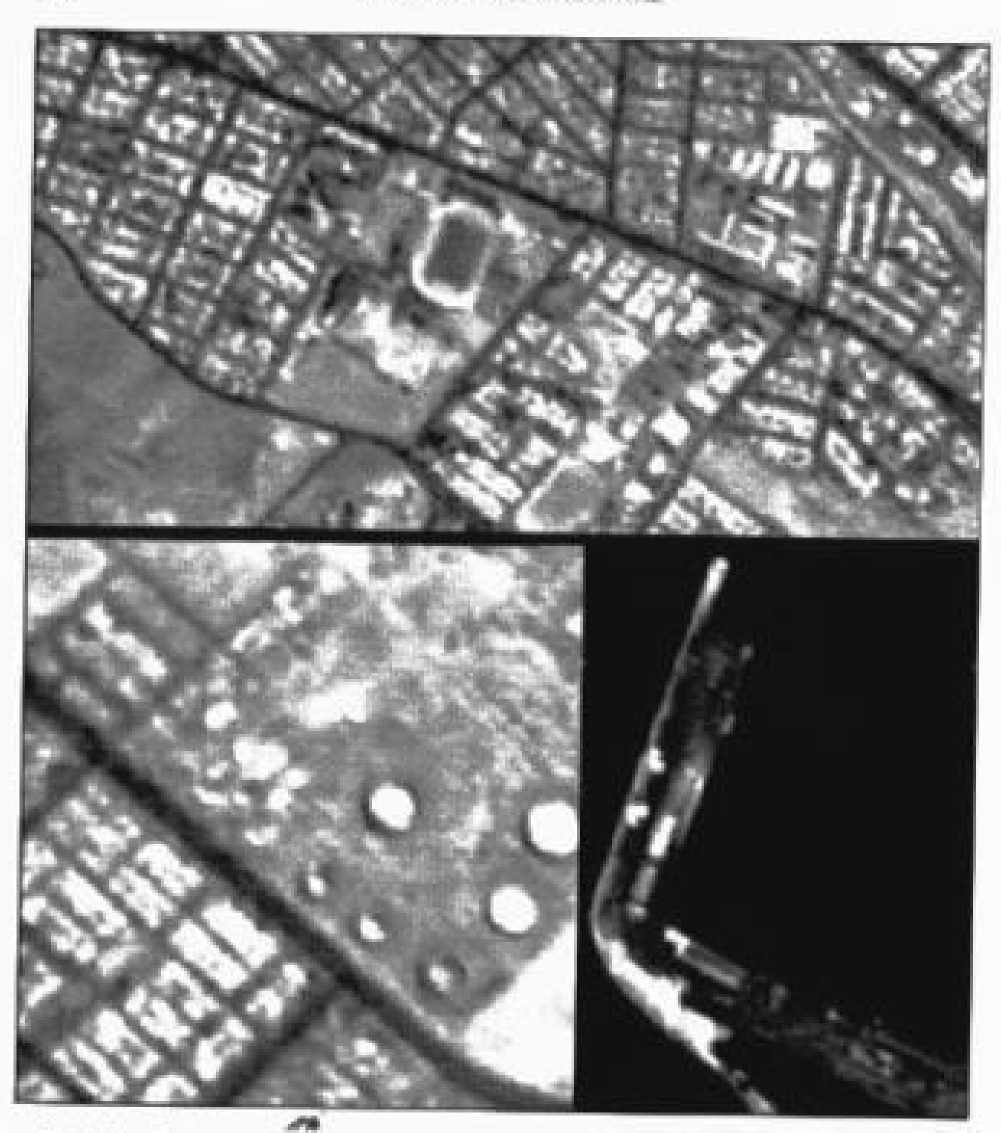


FIG. 3.32. *Fragmentos de una imagen IRS-1C de la ciudad de Arica (Arica 00), en el norte de Chile, donde pueden observarse con gran detalle algunos rasgos de la morfología y estructura urbana.*

Este ambicioso programa de observación de la Tierra indio se ha completado recientemente con dos nuevos satélites. En 2003 se lanzó el IRS-P6, denominado Resourcesat, que cuenta con tres sensores: una cámara de 3 bandas espectrales y resolución de 5,8 m, otra de cuatro bandas y 23,5 m, y una versión mejorada del WIFS, denominada AWIFS, con cuatro bandas y 70 m de resolución. En mayo de 2005 se lanzó el Cartosat-1, que cuenta con dos cámaras pancromáticas con una resolución espacial de 2,5 m que adquieren simultáneamente imágenes desde dos ángulos, lo que permite emplear estos datos para observación estereoscópica.

5.4. Satélites comerciales de alta resolución

Designa este término a una nueva generación de satélites promovidos por consorcios privados que pretenden impulsar la comercialización de imágenes de satélite hacia nuevos mercados hasta ahora reservados a la fotografía aérea.

Característica común a estas iniciativas es la búsqueda de altas resoluciones espaciales (entre 0,5 y 4 m), principalmente de cara a las aplicaciones urbanas de esta tecnología. Los principales desarrollos en esta línea se han liderado por tres empresas norteamericanas: *Space Imaging*, *Orbimage* y *Earthwatch Inc* (recientemente rebautizada *Digital Globe*), y una israelí (*ImageSat Int.*). La primera es propietaria del Ikonos-2, en órbita desde septiembre de 1999 después de un lanzamiento fallido en 1998. Cuenta con una resolución de 1 m en pancromático y 4 m en multiespectral (A, V, R, IRC). El área abarcada en cada imagen es de 11 km, y pueden adquirirse «tiras» de hasta 11 × 1.000 km. Las imágenes se cuantifican en 11 bits de resolución radiométrica, lo que ofrece una alta sensibilidad para discriminar cubiertas terrestres. Los datos se comercializan a través de una red de distribuidores comerciales, pero la recepción de las imágenes está centralizada. En este momento se cuenta con antenas terrestres en EE. UU., India, Emiratos Árabes, Alemania y Taiwán. La figura 3.33 recoge un ejemplo de las magníficas posibilidades que brinda este satélite para el análisis urbano.

Orbimage, por su parte, fue la pionera en lanzamientos comerciales, al poner en órbita en 1995 el Orbview-1, orientado a fines meteorológicos. También es propietaria del Orbview-2, que incluye el sensor oceanográfico, el Seawifs, en colaboración con la NASA. El Seawifs es un radiómetro de 8 canales (entre 0,4 y 0,88 μm), principalmente orientado al estudio del color del océano. Posee una resolución de 1,6 km, y un área abarcada de 2.800 km. Entre sus proyectos de alta resolución, la empresa *Orbimage* tiene previsto lanzar el Orbview-3, que contaría con una cámara pancromática de 1 m de resolución y otra multiespectral con 4 m, operando en 4 bandas del espectro (A, V, R, IRC). El área abarcada sería de 8 km, con un período de revisita (orientando la cámara para observaciones no verticales) de 3 días. Finalmente, el Orbview-4 añadía a estas dos cámaras un sensor hiper-espectral (inicialmente denominado *Warfighter*), con pretensión de recoger información de 200 canales del espectro (entre 0,45 y 2,5 μm) para pequeñas franjas del terreno (5 km de ancho), con una resolución de 8 y 20 m (según el tipo de usuarios). Este satélite se lanzó, sin éxito, en septiembre de 2001, con la consiguiente incertidumbre sobre el inmediato futuro de esta interesante iniciativa.

Por su parte, la empresa *Digital Globe* se responsabiliza de la operación del *Quickbird*, que fue lanzado el 18 de octubre de 2001, tras el fracaso de algún lanzamiento previo. Este satélite incorpora dos cámaras CCD, una pancromática, con 61 cm de resolución espacial (ver fig. 1.4) y una multiespectral con 2,5 m (A, V, R, IRC). El área cubierta es de 17 km, con «tiras» que pueden llegar a 17 × 225 km. La cuantificación de los datos se realiza en 11 bits por píxel. El período de revisita, para observaciones no verticales, puede reducirse, siempre según datos de la propia empresa, a 1-3,5 días.

Finalmente, la empresa *ImageSat International*, establecida en 1997, cuenta con participación de varios países, aunque está liderada por un consorcio israelí, y tiene su sede central técnica en Chipre. Lanzó en 2000 el primer satélite de la serie EROS (el A1), que cuenta con una cámara pancromática de 1,8 m de resolución, con un área



FIG. 3.33. *Imagen Ikonos de la ciudad de Barcelona.* (Cortesía: Indra Espacio.)

abarcada de 12,5 km y codificación en 11 bits, y capacidad de cobertura estereoscópica. Se pretenden poner en órbita otros satélites de esta serie que mejorarán la resolución hasta 0,82 m con capacidad multiespectral. Se pretende que esta constelación proporcione una cobertura potencial diaria de todo el planeta a esa alta resolución espacial.

5.5. TIROS-NOAA

Esta familia de satélites constituye uno de los múltiples programas diseñados para enviar información meteorológica a la superficie terrestre. Los satélites meteorológicos son los que cuentan con una mayor solidez en la serie de datos disponible, ya que vienen siendo plenamente operativos desde los años setenta. El primer satélite de la serie se lanzó en los años sesenta, denominándose entonces TIROS. Más tarde pasan a denominarse NOAA *(National Oceanic and Atmospheric Administration Satellite)*, la agencia meteorológica que los gestiona, a partir del sexto satélite, que se lanzó en 1979.

Teniendo en cuenta que el principal objetivo de esta misión era facilitar información sobre el estado actual de la atmósfera, el satélite NOAA se diseñó para ofrecer un ciclo de cobertura muy corto: una imagen cada doce horas en nuestras latitudes. Este ciclo se mejora a seis horas gracias a la sincronización entre los dos satélites que operan simultáneamente. Su altura orbital es de 833 a 870 km, cubriendo en una imagen un área aproximada de 3.000 km de lado.

En lo que se refiere a aplicaciones terrestres, el sensor más interesante del programa NOAA es el denominado AVHRR (*Advanced Very High Resolution Radiometer*: Cracknell, 1997), diseñado para proporcionar imágenes con una resolución de 1,1 km (en el nadir), en 5 bandas del espectro (R, IRC, IRM, IRT: tabla 3.4). Inicialmente los NOAA con numeración par obtenían imágenes aproximadamente a las 7,30 y 19,30 GMT en el Ecuador, mientras los impares lo hacían a las 14,30 y 2,30 GMT. Actualmente, y debido a diversos problemas en el lanzamiento de algunos satélites, esta regla ya no puede aplicarse. Además, las órbitas se degradan desde el año de lanzamiento, retrasándose incluso considerablemente, lo que conviene tener en cuenta de cara a homogeneizar adecuadamente las series temporales (Privette *et al.*, 1995).

Para asegurar esta frecuencia de adquisición, el AVHRR cuenta con un ángulo de barrido muy amplio (55,4° a ambos lados de la traza), lo que implica notables problemas geométricos y radiométricos en las imágenes resultantes. De esta forma, la resolución espacial del nadir (1,1 × 1,1 km) puede degradarse hasta 2,4 × 6 km en

TABLA 3.4. *Rango espectral del sensor AVHRR-NOAA (μm)*

AVHRR/1[1]		*AVHRR/2*[2]		*AVHRR/3*[3]		
				Diurna		*Nocturna*
1	0,58-0,68	1	0,58-0,68	1	0,58-0,68	0,58-0,68
2	0,72-1,10	2	0,72-1,10	2	0,72-1,10	0,72-1,10
3	3,55-3,93	3	1,58-1,64	3	1,58-1,64	3,55-3,93
4	10,3-11,3	4	10,3-11,3	4	10,3-11,3	10,3-11,3
		5	11,5-12,5	5	11,5-12,5	11,5-12,5

Resolución espacial: todos 1,1 × 1,1 km (en el nadir)

1. En los satélites pares hasta el NOAA-10.
2. En el resto hasta el NOAA-15.
3. A partir del NOAA-15.

los extremos de la imagen. Esto, añadido a los problemas de contaminación atmosférica de los píxeles extremos, desaconseja el empleo de los sectores de la imagen que excedan 30° del nadir (Goward *et al.*, 1991). Estos problemas de observación oblicua se ponen especialmente de manifiesto cuando pretendemos generar un mosaico sobre áreas muy extensas, ya que frecuentemente tendremos que contar con imágenes adquiridas en condiciones de observación muy dispares. La figura 3.34, por ejemplo, muestra un mosaico de imágenes AVHRR sobre el Mediterráneo, denotándose con claridad las zonas fronterizas entre imágenes, como la que aparece en el noreste peninsular.

Las imágenes AVHRR se presentan en tres diferentes formatos: la máxima resolución es denominada LAC *(Local Area Coverage)*, cuando se graba a bordo, o HRPT *(High Resolution Picture Transmission)*, cuando se envía en tiempo real a las estaciones receptoras. Puesto que el sistema de grabación del NOAA es bastante reducido, normalmente sólo se almacena a bordo un producto de menor resolución, llamado GAC *(Global Area Coverage)*, con un tamaño de píxel de 4 × 4 km, que se genera a partir de un muestreo de los datos LAC. Por último, también se produce semanalmente un producto denominado GVI *(Global Vegetation Index)*, calculado a partir de los canales infrarrojo cercano y rojo, para un píxel de 16 km de lado (Kidwell, 1990).

Gracias a su buena cobertura temporal y bajo coste —las imágenes son de libre recepción—, el sensor AVHRR se ha utilizado profusamente en los últimos años, no sólo para aplicaciones climáticas u oceanográficas, sino también para aplicaciones terrestres (Ehrlich *et al.*, 1994). Lógicamente, su resolución espacial no permite emplearlo en estudios de detalle, pero sí resulta muy fructífero para escalas globales (Potter y Brooks, 2000) y regionales (fig. 5*). Al proporcionar información del visible, infrarrojo cercano y térmico, permite seguir las condiciones de la vegetación en períodos cortos de tiempo y a escala global, lo que le hace idóneo para estudiar fenómenos muy dinámicos como la desertificación (Becker y Choudhury, 1988), la deforestación tropical (Malingreau *et al.*, 1989; Shimabukuro *et al.*, 1994), o los incendios forestales de gran magnitud (Chuvieco y Martín, 1994; Fernández *et al.*, 1997; Fraser *et al.*, 2000). Asimismo, se

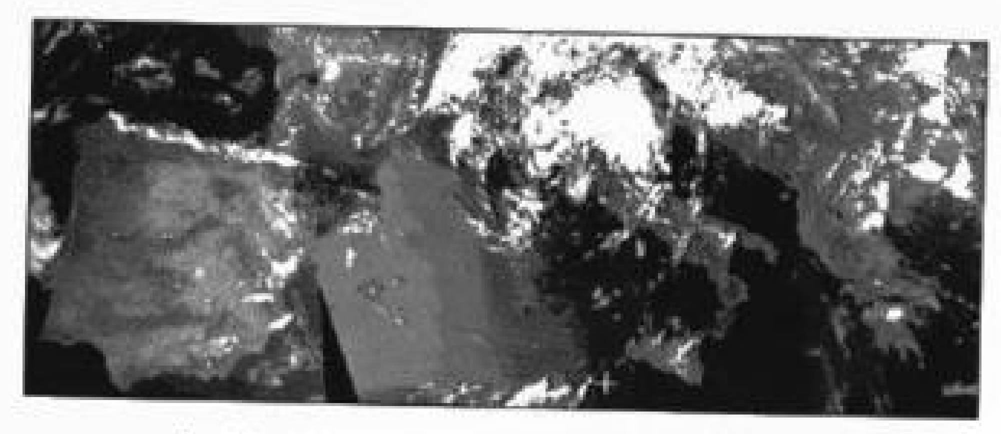


FIG. 3.34 *Mosaico de imágenes AVHRR sobre el Mediterráneo.*

está empleando para obtener mapas de la cobertura del suelo a escala continental (Tucker *et al.*, 1985), y para el inventario de cosechas (Gallo y Flesch, 1989; Teng, 1990).

Además del AVHRR, el satélite NOAA lleva otros sensores de interés meteorológico como son la sonda TOVS *(Tiros Operational Vertical Sounder)*, el sensor SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer)*, para medir las concentraciones verticales de ozono en la atmósfera, y el ERBE *(Earth Radiation Budget Experiment)*, con una resolución de 200 a 250 km en el nadir, dedicado al análisis de la radiación global. La sonda TOVS está formada por tres sensores que realizan un perfil vertical de la atmósfera para mediciones de temperatura y, en menor medida, de humedad y contenido total de ozono. Se trata del HIRS/3 *(High Resolution Infrared Radiation Sounder)*, que posee un radiómetro de 19 canales en el infrarrojo (3,76-14,95 μm) y 1 en el visible (0,69 μm), con una resolución espacial de 17 km en el nadir; el MSU *(Microwave Sounding Unit)*, radiómetro de micro-ondas con cuatro canales cercanos a los 55 GHz y una resolución espacial de 109 km en el nadir, y el SSU *(Stratospheric Sounding Unit)*, radiómetro infrarrojo de presión modulada con 3 canales en 15 µm y una resolución espacial en el nadir de 147 km. Los sensores MSU y SSU han sido sustituidos en los NOAA-15 y 16 por el AMSU A y B, el primero es un radiómetro de micro-ondas de 15 canales que proporciona sondeos más precisos de temperatura y humedad atmosférica. El AMSU B es un radiómetro de micro-ondas de 5 canales especialmente localizados para realizar mediciones de vapor de agua.

Finalmente, conviene tener en cuenta que existen otros satélites meteorológicos de órbita polar, con características más o menos similares a las del NOAA. Los más conocidos son el ruso METEOR, activo desde 1991, con dos bandas de observación en el VIS y en el IRT, y el chino Feng Yun, lanzado por vez primera en 1988. En las últimas versiones cuenta con 10 canales (VIS, IRC, SWIR, IRT), una resolución espacial aproximada de 1 km^2, y al igual que el NOAA las imágenes pueden recibirse libremente a partir de una antena receptora de coste medio.

En un inmediato futuro se prevé que haya una fusión entre la gestión de los programas geoestacionarios y de órbita polar europeos y norteamericanos. Para ello se ha acordado que la agencia meteorológica Eumetsat (actual gestor del programa Meteosat) pase a responsabilizarse en el futuro de uno de los dos satélites de órbita polar activos (el otro seguiría siendo responsabilidad de la NOAA). Esto implicará un mejora en los sensores disponibles que complementen las que se piensan introducir en los satélites geoestacionarios.

5.6. SATÉLITES METEOROLÓGICOS GEOESTACIONARIOS

Los satélites meteorológicos más populares, sin duda, son los de órbita geoestacionaria, ya que son los más utilizados en los medios de comunicación. Estos satélites proporcionan la mayor frecuencia temporal de observación (30 minutos), lo que les hace idóneos para seguir fenómenos atmosféricos muy dinámicos. Actualmente existe una red de satélites geoestacionarios coordinada por la organización meteorológica mundial, a través de su programa GARP *(Global Atmospheric Research Programme)*. Forman parte de esta red los satélites Meteosat, GOES, GMS, Insat y GOMS.

El primer satélite geoestacionario se lanzó en 1966 por la NASA, denominándose ATS *(Applications Technollogy Satellite)*. En forma operacional, este satélite se convirtió en la serie SMS, bautizada como GOES *(Geostationary Operational Environmental Satellite)* a partir de 1975. En el momento presente se cuenta con cuatro satélites de esta familia, aunque sólo dos resultan operativos. Cubren el conjunto del territorio norteamericano, así como el Atlántico oeste. Los más modernos incluyen varios sensores, entre los que destaca el *Imager*, sensor de barrido con cinco canales (1 VIS, 2 IRM, 2 IRT), que registra el disco visible de la Tierra cada 30 minutos, ofreciendo una resolución de 1 km para el visible y 4 km para 3 de las cuatro restantes bandas. Además cuenta con otro sensor, denominado *Sounder*, que ofrece un perfil de temperatura y humedad atmosférica, así como la distribución de ozono.

Similar configuración a la plataforma GOES tiene el satélite europeo Meteosat, aunque cuenta, por el momento, con peor resolución espacial y espectral. Lanzado por vez primera en 1977, hasta el momento se han puesto en órbita seis Meteosat más en 1981, 1988, 1989, 1991, 1993 y 1997, contribuyendo de modo decisivo a la predicción meteorológica en Europa y África. Inicialmente todos ellos se situaban en longitud 0°, pero el Meteosat-3 se desplazó hacia el Oeste para facilitar el seguimiento de huracanes tropicales. Estos satélites cuentan con un sensor de barrido, que ofrece información sobre tres bandas del espectro: 0,4 a 1,1 μm, 5,7 a 7,1 μm y 10,5 a 12,5 μm (ver fig. 3.4). La primera es bien conocida por su aparición en los medios de comunicación. La segunda se emplea para estudiar el contenido de vapor de agua en la atmósfera, mientras la tercera (térmica) se dirige a la discriminación de tipos de nubes y temperaturas de superficie. La resolución espacial que ofrece es de 2,5 × 2,5 km en el visible y 5 × 5 km en el infrarrojo medio y térmico. La imagen completa del Meteosat cubre el disco visible de la Tierra, desde su posición a 0° de latitud y longitud (fig. 6*). Estos satélites proporcionan imágenes cada 30 minutos. La transmisión se realiza en tiempo real a la estación receptora de Darmstadt (Alemania), en donde se sitúan las oficinas centrales de Eumetsat. Tras algunas correcciones, estos datos son enviados a una amplia red de estaciones receptoras, ya sea en alta resolución digital (a las estaciones primarias, *Primary Data User Stations*, PDUS), o en modo analógico.

La nueva generación de satélites Meteosat (MSG, *Meteosat Second Generation*) mejora notablemente la información proporcionada por esta plataforma. Esta nueva serie de satélites está activa desde 2004, y cuenta con mejoras de la resolución temporal —de 30 a 15 minutos—, espacial —hasta 1 km en el visible y 3 en el resto—, y espectral, incorporando nuevas bandas en el VIS, IRM e IRT (hasta 12 canales). Esto aumenta notablemente el flujo de datos brutos que envía el satélite (de 0,33 Mb/sg a 3,2 Mb/sg), complicando tanto su envío (nuevos sistemas de comunicaciones), como su recepción. Por el contrario, permite mejorar notablemente el rango de aplicaciones de estas imágenes, no sólo en cuestiones meteorológicas, sino también en temas ambientales de diverso tipo (Pereira y Govaerts, 2001).

Como es lógico, la aplicación básica de estos satélites meteorológicos es la observación de las condiciones atmosféricas, de cara a predecir el tiempo. Algunas variables que pueden obtenerse a partir de los datos suministrados por estas plataformas son la cobertura y tipo de nubes, el contenido de vapor de agua en la atmósfera, la precipitación acumulada, el viento superficial y en altura, el albedo superficial, la irradiancia solar, y la temperatura del agua del mar (Carleton, 1991). Resultan, además, de especial relevan-

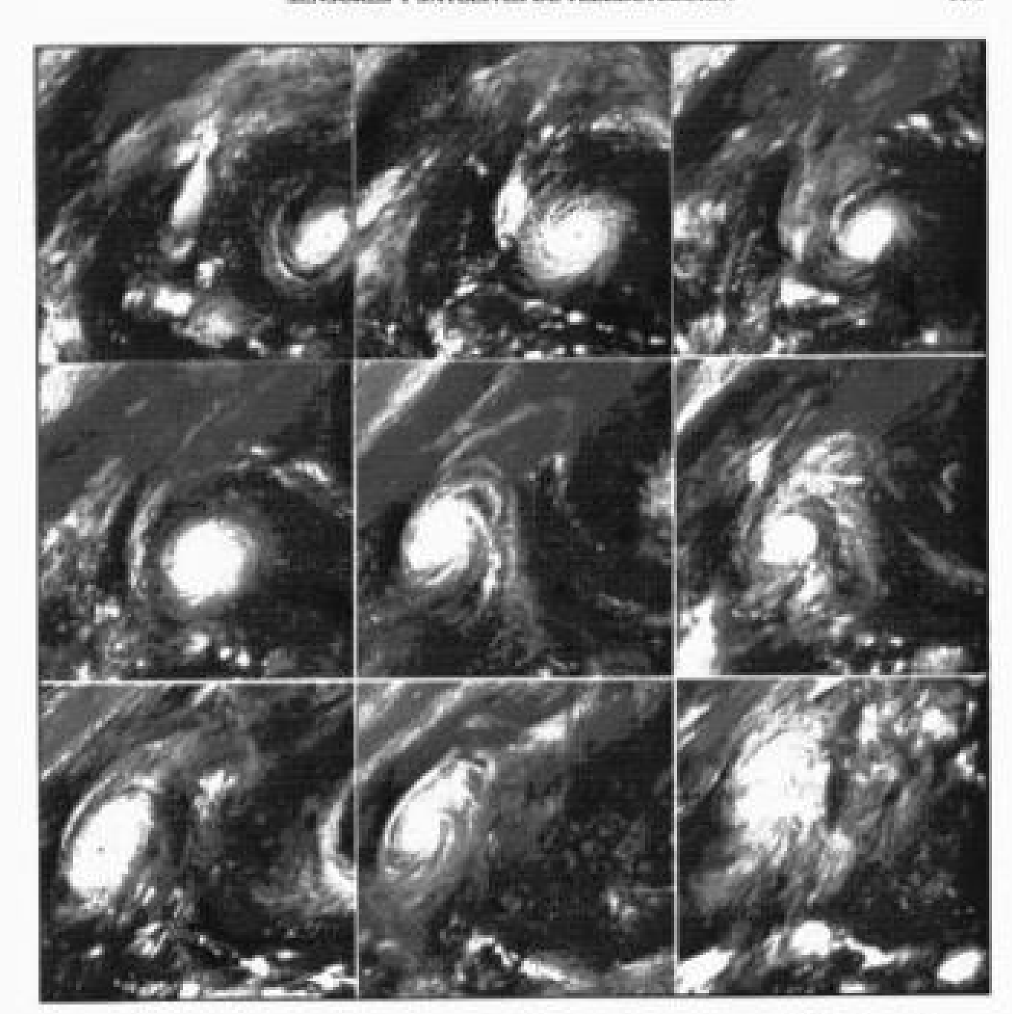


FIG. 3.35. *Seguimiento de la evolución del huracán* Andrew *(agosto de 1993) a partir de imágenes del Meteosat-3.* (Cortesía: ESA.)

cia en la estimación de fenómenos catastróficos, como huracanes (fig. 3.35) o gotas frías. En conjunción con otras plataformas heliosíncronas (como NOAA o Feng Yun), la meteorología desde satélites se destaca actualmente como la principal aplicación operativa de la teledetección espacial (Conway, 1997).

5.7. TERRA

Se trata del proyecto más ambicioso de la NASA para su sistema global de observación de la Tierra (EOS, *Earth Observing System*), que incluye otras plataformas de observación terrestre. Lanzado en diciembre de 1999 incorpora una gran variedad de sensores, que se complementan para generar variables de gran interés ambiental.

Los principales objetivos científicos de esta misión se centran en proporcionar a científicos interesados en procesos globales información crucial sobre la distribución de aerosoles, nubosidad, temperatura terrestre y marina, cambios en los usos/coberturas del suelo y el papel de los océanos en el cambio climático.

La plataforma está situada en una órbita heliosíncrona, cruzando el Ecuador en torno a las 10,30 solares. La carga útil del Terra está formada por los siguientes sensores:

— *ASTER*

El ASTER *(Advanced Spaceborne Thermal Emisión and Reflection Radiometer)* es el único sensor de alta resolución espacial incluido en el satélite. Fue construido por Japón, que se encarga también de la distribución de datos. Cuenta con 15 canales: 4 con 15 m de resolución (V, R, 2 IRC), el último de ellos estereoscópico con la misma longitud de onda que el tercero; 6 con 30 m de resolución en el SWIR, y otros 5 en el IRT. Sus objetivos principales son medir las propiedades de las nubes, estudios de vegetación y suelos, temperatura terrestre y topografía. Puesto que se adquieren las imágenes simultáneamente con otros sensores del Terra, una de sus principales aplicaciones es la verificación de resultados obtenidos con sensores menos precisos espacialmente. Es el único instrumento del satélite que no toma datos constantemente, sino sólo durante algunos minutos de la órbita, lo que requerirá varios años de trabajo para construir un mosaico global a la resolución de 15 m (por ejemplo, de cara a obtener un MDT global de todo el mundo).

En la figura 7* se incluye un magnífico ejemplo de las imágenes tomadas por este sensor correspondiente al estrecho de Gibraltar. La imagen, adquirida en el verano de 2000, cubre una zona de unos 60 km de largo y 34 de ancho. Permite observar los rasgos más destacados de la bahía de Algeciras, al norte, y la ciudad de Ceuta, al sur, además de la notable configuración del Peñón de Gibraltar.

— *CERES*

El sensor CERES *(Clouds and the Earth's Radiant Energy System)* mide el balance de radiación global terrestre y proporciona estimaciones sobre las propiedades de las nubes. Continúa las experiencias adquiridas en misiones previas como ERBE a bordo de los satélites NOAA. Se trata de un sensor con tres canales, VIS para medir la radiación de onda corta, IRT para medir la de onda larga, y completo (de 0,3 a 100 μm) para medir el flujo completo de radiación. En el Terra se han incluido dos equipos que funcionan simultáneamente con dos ángulos de barrido distintos (perpendicular a la traza y circular), lo que le permite obtener un perfil vertical de la atmósfera. Este sensor ya se instaló en la misión TRMM, para el análisis de zonas tropicales, y además de en el Terra está previsto que embarque en el Aqua.

— *MISR*

Como antes indicamos, el MISR *(Multi-Angle Imaging Spectroradiometer)* es uno de los primeros sensores en proporcionar una cobertura multiangular de todo el planeta. Tiene capacidad de observar simultáneamente 9 ángulos distintos (además



FIG. 3.36. *Imagen MISR de las islas Canarias tomada el 29 de Febrero de 2000.* (Cortesía: NASA, http://visibleearth.nasa.gov)

del nadir, a 26,1-45,6 -60 y 70°, tanto hacia delante como hacia atrás de la órbita) y 4 bandas espectrales (A, V, R, IRC). Esta configuración le permite realizar estimaciones bastante precisas del espesor óptico de la atmósfera, análisis bastante pormenorizados de la cantidad, tipo y altura de las nubes, y estudiar el efecto de las condiciones de observación sobre la reflectividad de las cubiertas terrestres. El área abarcada en cada imagen es de 360 km de ancho y la resolución es muy variable, dependiendo del ángulo de observación. En el nadir es de 275 m si bien se remuestrea a píxeles más grandes para coberturas de grandes superficies.

La imagen 3.36 muestra un ejemplo de los datos adquiridos por este sensor. Se trata de una adquisición multiangular sobre las islas Canarias a 70,5° de visión hacia delante de la trayectoria (izquierda), nadir (central) y hacia atrás (derecha). Puesto que las bandas espectrales son las mismas, la variación de tono es debida únicamente a la diversidad de espesor atmosférico en las tres adquisiciones. Muestra una tormenta de polvo proveniente del Sahara, que resulta mucho más evidente en las adquisiciones oblicuas. La resolución en estas imágenes está degradada a 1 km.

— *MODIS*

El *Moderate-Resolution Imaging Spectroradiometer* (MODIS) es el primer sensor con capacidad hiperespectral lanzado al espacio. Cuenta con 36 canales, a distintas resoluciones y ámbitos del espectro. Las dos primeras bandas cuentan con 250 m de resolución cubriendo el R e IRC. Las 5 siguientes ofrecen 500 m y cubren el V y diversas bandas del SWIR. El resto, con una resolución de 1 km cubren principalmente el VIS-IRC (entre 0,4 y 9,965 μm hay 12 bandas), y el IRM y térmico (6 bandas entre 10,78 y 14,38 μm). Cuenta con un área de barrido de 2.300 km, lo que le facilita una cobertura prácticamente diaria de la Tierra (fig. 8*). Las aplicaciones que se están abordando son muy numerosas, desde cartografía precisa de la cubierta nubosa y aerosoles, hasta la actividad fotosintética, detección de incendios o erupciones volcánicas, cartografía de la superficie marina o la cobertura de nieve, gracias a la cuasi libre distribución de estos datos (pueden obtenerse directamente a través de la red de distribución de datos de la NASA: *Distributed Active Archive Center Alliance*, DAAC: http://daac.gsfc.nasa.gov).

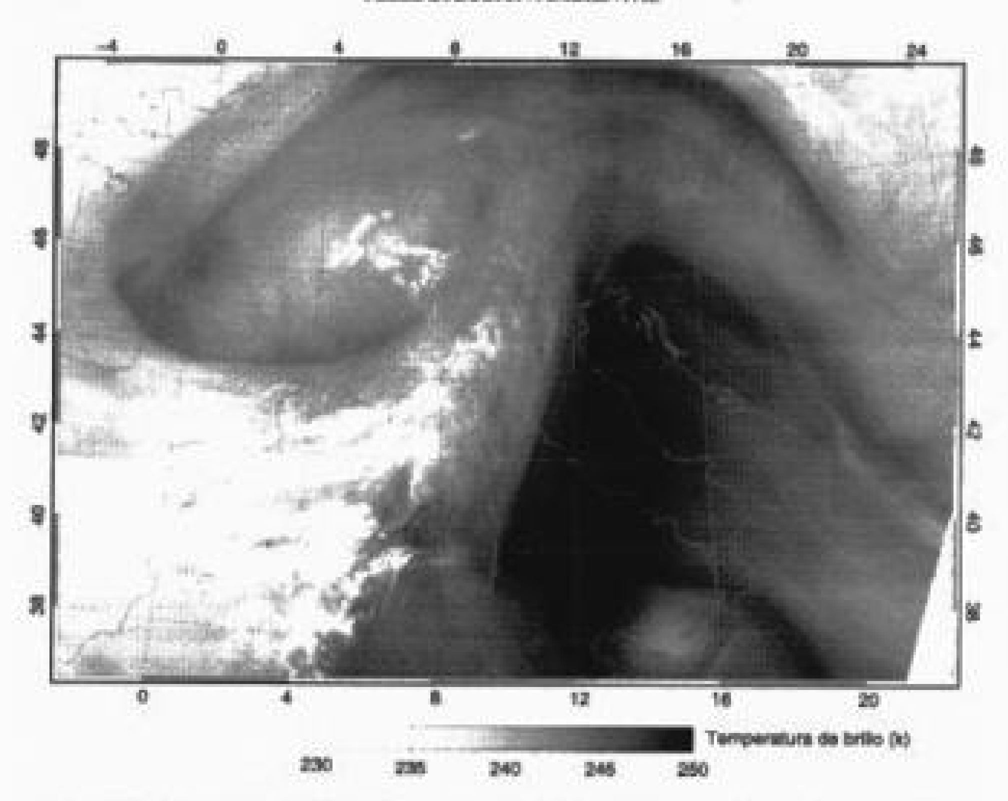


FIG. 3.37. *Imagen adquirida el 7 de marzo por el MODIS correspondiente a la temperatura de brillo registrada en el IRM para el centro y sur de Europa.*
(Cortesía: NASA, http://visibleearth.nasa.gov)

La figura 3.37 muestra un ejemplo de los productos generados por este sensor. Se trata de una imagen correspondiente a la temperatura de brillo del canal 27, situado entre 6,5 y 6,89 μm, que permite determinar la temperatura del vapor de agua. La imagen corresponde al sur de Europa e incluye buena parte de nuestro país, el sur de Francia e Italia.

— *MOPITT*

El MOPITT *(Measurements of Pollution In The Troposphere)* es un sensor primordialmente diseñado para estudiar las condiciones de la baja atmósfera, particularmente cómo interacciona con las superficies terrestres y marinas. Pretende estimar la distribución, transportes, fuentes y sumideros de monóxido de carbono y metano en la troposfera. Utiliza una técnica novedosa (correlación espectroscópica de gases), midiendo la energía reflejada y emitida desde la Tierra en tres bandas espectrales (en el IRM), que pasa a través de diferentes rutas por unas cápsulas a bordo con monóxido de carbono y metano. Las diferencias observadas en la absorción permiten estimar el contenido en la atmósfera de estos gases. Este sensor tiene una resolución de 22 km en el nadir y abarca un área de 640 km.

Se pretende que todos estos sensores embarcados en el satélite Terra tengan una continuidad a medio plazo, incluyéndose en otras misiones futuras de teledetección. En pocos meses, algunos de estos sensores se incluirán en el satélite Aqua, que pretende complementar la órbita del Terra, orientándose un poco más hacia la observación de los océanos (lanzamiento previsto a mediados de 2002). Incluirá los sensores MODIS y CERES, además de otros específicos (radiómetros de micro-ondas y sondas atmosféricas). Incluirá también un sensor diseñado por Brasil destinado a obtener perfiles de la humedad atmosférica.

5.8. DMSP

Los satélites de la serie DMSP *(Defense Meteorological Satellite Program)* se diseñaron inicialmente con el propósito de facilitar información global y diaria sobre la cobertura de nubes, con fines militares. Dotados originalmente con sistemas de vídeo, a partir de los años setenta se mejoran con equipos de exploración y radiómetros pasivos de micro-ondas. Gracias a la continuidad de la serie (ya están construidos satélites de esta serie hasta el año 2005), y a su reciente disponibilidad para aplicaciones civiles, se trata de una información de gran interés para la observación global, completando la proporcionada por el AVHRR del NOAA. El DMSP cuenta con varios sensores de exploración meteorológica, dedicados a observar las condiciones de las capas medias y altas de la atmósfera.

Para aplicaciones terrestres, los sensores más interesantes a bordo del DMSP son el SSM/I *(Special Sensor Microwave Imager)*, radiómetro de micro-ondas, que completa las medidas realizadas por el Nimbus en los años setenta, y el OLS *(Operational Linescan System)*, que es el sensor más importante de la misión. El OLS es un equipo de barrido que proporciona imágenes diurnas y nocturnas en dos bandas: visible (0,5 a 0,9 μm) e infrarrojo térmico (10,5 a 12,6 μm). La resolución espacial puede llegar a 0,56 km, aunque habitualmente se graba sólo una versión degradada, a 2,7 km. Una curiosa capacidad de este sensor es adquirir imágenes nocturnas en el visible, gracias a amplificar notablemente su sensibilidad radiométrica. Esto le permite detectar focos de luz, ya sean urbanos, pozos de petróleo o incendios, obteniendo imágenes muy espectaculares de los patrones urbanos a escala global (Elvidge *et al.*, 1997) y sirviendo de complemento a otros sistemas para la detección de incendios (Elvidge, 2001; Fuller y Fulk, 2000).

La figura 3.38 ofrece una visión global de los núcleos urbanos de la península Ibérica, tal y como se observan por este sensor. Resultan evidentes las principales concentraciones de población: Madrid, Lisboa, litoral catalán y valenciano, Sevilla, Granada, el eje asturiano, etc., así como los vacíos demográficos más destacados, Pirineos, Sistema Ibérico y Cantábrico, Sierra Morena, etc.

5.9. ERS-ENVISAT

El primer satélite de teledetección diseñado por la Agencia Espacial Europea (ESA) se denominó ERS *(European Remote Sensing Satellite)*. Este satélite fue lanzado por vez primera en 1991, siguiéndole otro similar en 1995. Su desarrolló intentaba complementar la observación proporcionada por los equipos ópticos (instalados a bor-

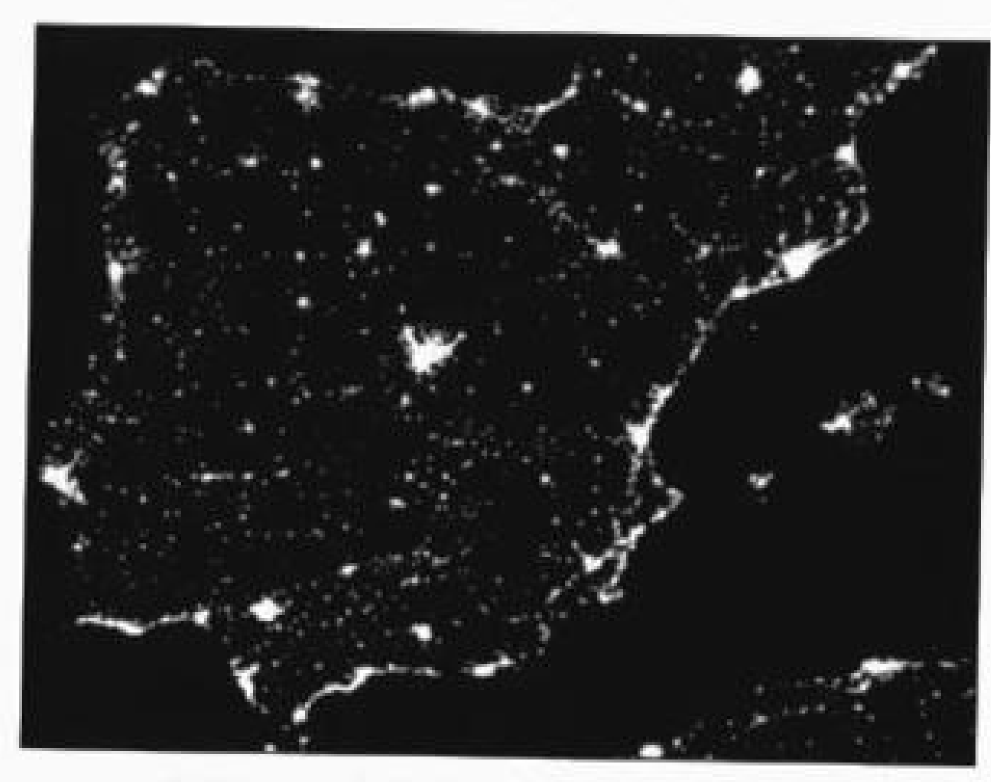


FIG. 3.38. *Imagen DMSP de la península Ibérica.* (Cortesía: NGDC.)

do del Landsat o SPOT), y se dirigía principalmente al estudio del océano y la criosfera, aunque también se han observado muy interesantes aplicaciones en seguimiento de procesos terrestres. El ERS orbita a una altitud de 780 km, mide 12 × 12 × 2,5 m y pesa 2.400 kg (ESA, 1992).

Su carga útil se compone básicamente de dos sensores radar y un explorador de infrarrojo térmico. El equipo más importante, sin duda, es el instrumento activo de micro-ondas (AMI, *Active Microwave Instrument*), que incluye un radar de imágenes y un dispersómetro de vientos. El primero puede utilizarse en modo imagen, trabajando en banda *C* (5,3 Ghz), polarización vertical semejante, con una resolución espacial de 26 m en profundidad y entre 6 y 30 m en acimut, y un área cubierta de 102 km. El ángulo medio de incidencia es 23°. Como el flujo de datos es muy elevado, sólo se emplea cuando se encuentra en el área de alguna antena de recepción terrestre; además, sólo puede activarse 12 minutos por órbita. Este equipo también puede trabajar en modo «olas», directamente dirigido al estudio del oleaje marino. La resolución espacial es la misma, pero se disminuye drásticamente el área abarcada en cada adquisición (0,6 × 12 km). Por último, este equipo puede también funcionar como un dispersómetro, para medir la dirección y velocidad del viento en el océano, para lo que utiliza tres antenas que emiten pulsos hacia distintos ángulos. El área total cubierta es de unos 500 km de ancho, con una resolución aproximada de 45 km.

El segundo equipo de micro-ondas es un altímetro, trabajando en banda *K*

(13,8 Ghz), que permite observaciones verticales. Midiendo el tiempo que tarda en recogerse el pulso emitido es capaz de calcular la altura del oleaje con una precisión de 10 cm, lo que permitirá continuar las interesantes observaciones de la variación altitudinal de los océanos que ha realizado el ERS (fig. 10*). También puede utilizarse para medir el campo de vientos (complementando al AMI), y para estudiar la topografía de los campos de hielo.

Finalmente, el ERS incorpora un equipo de barrido térmico, denominado ATSR *(Along Track Scanning Radiometer)*, diseñado por un consorcio de empresas inglesas y australianas para proporcionar una medida precisa de la temperatura del agua del mar y del techo de las nubes. Cuenta con cuatro bandas en el SWIR, IRM e IRT. Ofrece una precisión de hasta 0,1 K, con una resolución espacial de 1 km en franjas de 500 × 500 km. En el ERS-2 se ha incorporado una versión mejorada de este sensor, denominado ATSR-2, que incorpora tres nuevas bandas en el visible e infrarrojo próximo y tiene capacidad de observación con dos ángulos.

Además, el ERS-2 incorpora además un instrumento específico para medir el contenido de ozono en la atmósfera. Se denomina GOME *(Global Ozone Monitoring Experiment)*, y proporciona medidas del contenido en la atmósfera de diversos gases (ozono, dióxido de nitrógeno, oxígeno, etc.), mediante una técnica de absorción espectroscópica diferencial.

Muy recientemente la ESA ha lanzado su proyecto de observación de la Tierra más ambicioso, el Envisat. Además de continuar las observaciones de los ERS, pretende realzar el papel de Europa en las misiones de observación global, con especial énfasis en el área de la química atmosférica y los estudios oceanográficos. Las variables críticas a observar son el estado de las condiciones marinas, incluyendo la temperatura superficial, de la capa de ozono, de la temperatura, presión, vapor de agua, altura de las nubes y balance de radiación, y del color del océano. Opera a una órbita heliosíncrona con 35 días de ciclo, a unos 800 km de altura. Lleva una amplia variedad de instrumentos científicos, entre los que destacan especialmente el radar de abertura sintética avanzado (ASAR), un sensor hiperespectral (MERIS), y un radiómetro térmico avanzado (AATSR).

5.10. Radarsat

Se trata de la primera plataforma de teledetección que desarrolla íntegramente Canadá. Lanzado en noviembre de 1995, tiene por objeto mejorar la disponibilidad de datos radar para aplicaciones terrestres (hasta ese momento, solo el ERS tenía radares orbitales), principalmente la agricultura, seguimiento forestal, hidrología, estudios oceanográficos y costeros.

El RADARSAT orbita a 798 km de altura con una inclinación de 98,6° sobre el plano ecuatorial. Incorpora un radar bastante avanzado, que puede operar en distintos modos, con variadas resoluciones espaciales, áreas de cobertura y ángulos de incidencia.[7] Lo común a todos ellos es su frecuencia (banda *C* = 5,3 Ghz), idéntica al

7. La revista canadiense de Teledetección *(Canadian Journal of Remote Sensing)* dedicó un número monográfico en noviembre de 1993 (vol. 19, número 4) a explicar con detalle las características técnicas de este equipo, así como su rango potencial de aplicaciones.



FIG. 3.39. *Imagen RADARSAT de las inmediaciones de La Plata (Argentina) tomada el 26 de enero de 1999.* (Cortesía: DAIS.)

ERS, y polarización horizontal semejante (HH). La resolución espacial puede variar entre 11 y 100 m, y el área cubierta entre 50 y 500 km. Para el modo estándar de operación, la frecuencia temporal es de 24 días. En cuanto al ángulo de incidencia, puede variar de modo operativo entre los 20 y 50°, alcanzando hasta 10 y 60°, en modo experimental.

Se prevé ampliar las operaciones de este satélite con el lanzamiento del RADARSAT-2 en 2003, que incorporará un radar más avanzado con una resolución espacial que puede llegar a 3 m, capacidad multipolarización, mayor resolución temporal y áreas de cobertura entre 20 y 500 km.

La figura 3.39 presenta un ejemplo de aplicación de las imágenes radar al estudio de la contaminación acuática. Se delimitan con claridad unos vertidos de petróleo que afectaron a la costa argentina en enero de 1999. El crudo presenta una señal de retorno más débil que al agua no afectada, al contar con mayor densidad.

5.11. OTROS PROGRAMAS DE OBSERVACIÓN TERRESTRE

Para terminar este repaso de los principales sistemas de teledetección espacial vamos a hacer una rápida referencia a otros proyectos, más efímeros o de aplicaciones más limitadas en nuestro país.

5.11.1. *Programas con sensores radar*

Además del RADARSAT y el ERS, se han adquirido imágenes por otros equipos activos de micro-ondas. El primero de estas características fue el Seasat, lanzado en 1978. Contaba con polarización semejante HH, un ángulo de incidencia entre 20 y 26° y 25 m de resolución espacial. Además, incorporaba un altímetro de bastante precisión. Sus principales aplicaciones eran oceanográficas, de ahí el nombre, principalmente una medición más precisa del geoide marino. Junto a ello, permitió abordar estudios sobre altura del oleaje, detección de bancos de arena sumergidos, corrientes oceánicas, etc. (Elachi, 1982). Pese a la brevedad de su misión —dejó de funcionar a los 99 días de su lanzamiento—, el rango de aplicaciones que ha alimentado es muy amplio. Junto a las oceanográficas, destacan la localización de accidentes geológicos (Koopmans, 1983), cartografía de la cobertura del suelo (Deane, 1980), de la vegetación (Parry, 1986), y del medio urbano (Henderson, 1983).

La fecunda misión del Seasat se vio ampliada sucesivamente por varios radar de imágenes instalados en el transbordador espacial norteamericano *(Space Shuttle)*. En concreto, las misiones de este equipo se desarrollaron en los años 1981, 1984 y 1994, con el nombre de SIR-A, B y C, respectivamente. Las dos primeras misiones son similares al SAR del Seasat, trabajando en la banda *L*, con resolución de 25 a 40 m, y polarización HH, aunque ofrecían un mayor ángulo de observación: 47° en el SIR-A y 15 a 60° en el SIR-B, gracias, en este último, a una antena direccionable. También en el SIR-B se introduce la grabación digital de los datos. El SIR-C supera los rasgos técnicos de sus predecesores, con tres bandas de observación (*L*, *C* y *X*), polarización semejante y cruzada, ángulo de observación variable (de 20 a 55°), resolución de 25 a 30 m y grabación digital. La acción de estos SAR ha permitido confirmar las posibilidades de este tipo de sensores para la cartografía temática (Llop *et al.*, 1987; Meliá y Sobrino, 1987).

En orden cronológico el siguiente satélite equipado con un radar de imágenes es el ruso Almaz, lanzado en marzo de 1991, aunque ya tenía un precedente en el Cosmos-1870, que también poseía un SAR trabajando en la banda *S* y con una resolución en terreno de 20-25 m. Almaz se consideraba un satélite operativo, gestionado comúnmente por la agencia espacial rusa y una serie de empresas privadas de otros países, pero su impacto comercial y científico ha sido muy escaso. Incluía un SAR que trabajaba en banda *S*, observando una zona de unos 40 × 30 km, con una resolución de 10 a 15 m. El ángulo de incidencia podía variar entre 30 y 60°, y la codificación de los datos es digital.

El satélite japonés JERS-1 supuso la aportación de este país a la teledetección con equipos SAR. Fue lanzado en 1992 y contaba con un radar trabajando en banda *L*, con polarización HH, ángulo de observación de 35° y resolución espacial de 20 m (cubriendo un área de 75 km de lado). Lamentablemente dejó de funcionar en 1998, aunque se prevé continuar las actividades de observación radar con misiones futuras como las del ALOS *(Advanced Land Observing System)* prevista para 2003.

La figura 3.40 recoge una imagen SAR del JERS-1 sobre la región centro-occidental española, comprendida entre la Sierra de Ayllón y el inicio del Sistema Ibérico. Se observan con claridad los embalses del Vado, el Atazar y Pálmaces, el cauce del Jarama y el Sorbe. Los núcleos de población aparecen con tonos más claros. Las vertientes de los pequeños arroyos, subsidiarios del Henares, están muy marcadas.

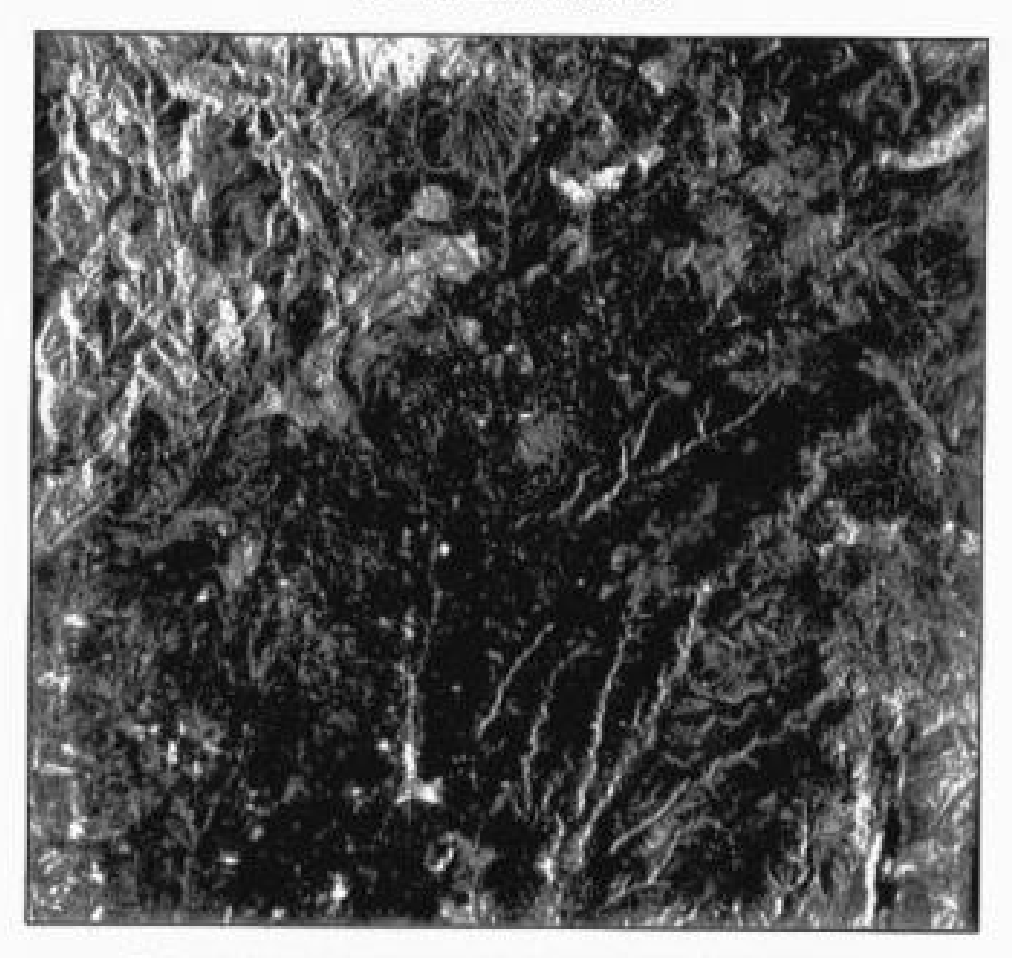


FIG. 3.40. *Imagen del radar del JERS-1 sobre la región central española.* (Cortesía: NASDA - *Earth Observation Center.*)

5.11.2. *Programas con sensores ópticos*

La agencia espacial japonesa (NASDA) ha sido bastante activa en programas de observación de la Tierra, a partir de los años ochenta. El primer satélite que lanzó fue el MOS *(Marine Observation Satellite)*, por vez primera en febrero de 1987, ampliándose la serie con una segunda plataforma en 1990. Se diseñó primariamente para la investigación oceánica, aunque también contaba con interesantes rasgos para su aplicación terrestre. Su carga útil se componía de los siguientes sensores: un equipo de exploración por empuje, bautizado como MESSR *(Multispectral Electronic Self-Scanning Radiometer)*, con una resolución de 50 m y cuatro bandas espectrales, dos en el visible y dos en el infrarrojo cercano; un explorador de barrido, denominado VTIR *(Visible and Thermal Infrared Radiometer)*, con una banda en el visible y tres en el infrarrojo térmico (resolución espacial de 900 y 2.700 m, respectivamente); y un radiómetro de micro-ondas, el MSR *(Microwave Scanning Radiometer)*, operando a

23 y 31 GHz, con resolución de 32 y 23 km, respectivamente (Tsuchiya *et al.*, 1987). De estos sensores, el más destacado para estudios medio ambientales fue el MESSR, similar al HRV-SPOT en cuanto a tecnología, al MSS en cuanto a resolución espectral, y a medio camino entre éste y el TM respecto a su resolución espacial. Este sensor ofrecía imágenes de 100 × 90 km, con un ciclo de recubrimiento de 17 días. Estuvo activo hasta 1996.

Además del radar, el JERS-1 contó con un radiómetro óptico, denominado OPS *(Optical Sensor)*, que proporcionaba información de 8 bandas en el VIS, IRC, SWIR con 18 m de resolución espacial. La banda 8 proporcionaba cobertura estereoscópica sobre la 3 (0,76 a 0,86 μm).

Sin embargo, el proyecto más ambicioso hasta el momento de la NASDA ha sido el satélite ADEOS, activo sólo entre 1996 y 1997 como consecuencia de un fallo en los paneles solares. El satélite incorporaba numerosos sensores de observación ambiental (un radiómetro VIS-IRC-SWIR avanzado, un sensor de color del océano, un dispersómetro, el TOMS, el POLDER, etc.). Se ha continuado esta misión con el lanzamiento del ADEOS-2 en 2002 y del ALOS en 2003.

La agencia espacial rusa ha sufrido diversas transformaciones en las últimas décadas, debilitándose considerablemente su papel en temas de observación de la Tierra, en gran parte debido a los problemas de comercialización que han tenido sus sensores. Entre los proyectos más destacados figuran los satélites meteorológicos METEOR-3 y GOMS, y los de recursos naturales RESURS y OKEAN. El METEOR incorpora una serie de cámaras de televisión de resolución media-baja (0,7 a 35 km, según los casos), así como algunos equipos diseñados por otros países para obtener perfiles atmosféricos (aerosoles y capa de ozono). El GOMS es un satélite geoestacionario de características muy similares al Meteosat (3 bandas, similar resolución espacial), situado a la longitud de 76° 50′ E. El RESURS tal vez es el de mayor interés, pues ha permitido tomar imágenes a una resolución intermedia entre el Landsat-MSS y el NOAA-AVHRR, siendo de interés para estudios de escala regional y continental. Cuenta con dos sensores de barrido multiespectral, el MSU-E con una resolución espacial mayor, y el MSU-SK, con resolución media (140 m en los canales ópticos, 550 en el térmico), facilitando información del verde, rojo, infrarrojo cercano y térmico.

Además de estas grandes agencias, otros países con menor tradición espacial han lanzado recientemente satélites al espacio, como es el caso de Corea, que lanzó en 1999 su primer satélite de observación de la Tierra, el Kompsat-1, equipado con una cámara pancromática de 6 m y otros sensores oceanográficos, Malasia, Taiwán o Israel. En el ámbito de nuestra área cultural vale la pena citar el proyecto brasileño-chino, denominado CBERS, y el argentino SAC-C. El primero cuenta con un tres radiómetros: WFI, 2 bandas, cobertura regional (890 km) y resolución media (260 m); una cámara de alta resolución (20 m) en 4 bandas espectrales, y un equipo similar al Landsat-MSS, aunque con capacidad térmica y observación en el SWIR. Por su parte, el SAC-C incorpora un sensor de resolución media, con 350 y 175 m y 5 bandas espectrales, así como otros sensores para el análisis de los campos geomagnéticos, sistemas de posicionamiento global y radiación espacial de baja órbita.

5.11.3. *Programas con sensores hiperespectrales*

Tal vez una de las principales novedades tecnológicas que ha irrumpido en la teledetección en la última década sea el creciente empleo de los sensores hiperespectrales. Se trata de equipos de muy alta resolución espectral que permiten obtener simultáneamente imágenes de un gran número de bandas. Hasta hace muy poco estos equipos eran muy escasos, por lo que los datos disponibles restringían notablemente el rango de aplicaciones. A bordo de aviones se realizaron algunos estudios en los inicios de los noventa con el sensor HIRIS *(High Resolution Imaging Spectrometer)*, dotado de 192 canales, distribuidos entre el VIS y el IRC. Estos sensores de alta resolución espectral permiten recoger información en bandas muy estrechas, discriminando parámetros críticos de la vegetación o los suelos, que no serían perceptibles con sensores convencionales. A partir de estas imágenes se obtuvieron variables biofísicas de gran interés para entender mejor el funcionamiento de la fisiología vegetal, como el contenido de clorofila, lignina, nitrógeno o de agua (Curran y Kupiec, 1995), así como algunos minerales presentes en el suelo (Kruse *et al.*, 1993*a*).

La puesta a punto del AVIRIS *(Airborne Visible/Infrared Imaging Spectrometer)* supuso un incremento considerable de este tipo de estudios. Este sensor, que vuela sobre un avión U2 y es operado por el *Jet Propulsion Laboratory* (JPL), facilita 224 canales contiguos, que van desde 0,4 a 2,5 μm, codificando los datos en 12 bits a partir de 1995. Esto permite realizar espectros continuos de una gran cantidad de paisajes, con resoluciones que van de 5 a 20 m, dependiendo de la altura de vuelo. La gama de estudios realizados con este sensor es muy amplia, si bien el análisis de rasgos vegetales (Chen *et al.*, 1998; Elvidge y Portigal, 1990; Kupiec y Curran, 1995; Roberts *et al.*, 1997*a*; Roberts *et al.*, 1997*b*) y de tipos de suelos (Adams *et al.*, 1986; Palacios-Orueta y Ustin, 1996; Palacios-Orueta y Ustin, 1998) han tenido una mayor repercusión. Los datos AVIRIS permiten extraer diversos parámetros estructurales de la cubierta forestal, como la edad de la plantación, la importancia del sustrato o el efecto de sombras (Ustin y Trabucco, 2000).

Además del AVIRIS, hay otros sensores hiperespectrales montados sobre avión. Tal vez los más conocidos son el DAIS *(Digital Airborne Imaging Spectrometer)*, gestionado por el DLR alemán, que es capaz de registrar 79 canales, la mayor parte en el VIS-IRC-SWIR, pero también con algunos en el IRM e IRT; el canadiense CASI *(Compact Airborne Spectrographic Imager)*, con un rango de 288 bandas entre 0,43 y 0,87 μm (la nueva versión del sensor cubre de 0,4 a 1 μm); y el australiano HyMap, con 125 bandas entre 0,4 y 2,5 μm. Con ser de gran interés, estos sensores son de orientación local, ya que no adquieren imágenes de modo sistemático, sino únicamente en estudios piloto, principalmente orientados a la innovación científica, aunque ya se cuenta también con aplicaciones comerciales de estas técnicas.

En los últimos años estas perspectivas se están ampliando con la puesta en órbita de los primeros sensores espaciales con capacidad hiperespectral. Como antes comentamos, el primero ha sido el MODIS, a bordo de la plataforma Terra. Aunque cuenta con 36 bandas, su carácter hiperespectral es algo dudoso, ya que no permite un registro continuo del espectro, sino diversas bandas aisladas, aunque ciertamente numerosas, de interés para la observación de determinadas variables. Sin embargo, sí podemos clasificar con toda justicia como hiperespectral al sensor Hyperion, instalado en la plataforma EO-1, lanzada en noviembre de 2000, que proporciona

220 bandas espectrales entre 0,4 y 2,5 μm con una resolución en terreno de 30 m, y un área abarcada de 7,5 × 180 km. El carácter experimental del Hyperion y su corta vida esperada (poco más de un año) han reducido mucho su difusión, pero se espera que sirva como banco de pruebas para evaluar el rendimiento de futuros sensores espaciales con capacidad hiperespectral. Si los planes se cumplen, al menos ya hay otras dos misiones que incorporarán sensores de alta resolución espectral, como son el MERIS (a bordo del Envisat) y el Warfighter-1, que se incluía en la carga útil del Orbview-4 (y esperamos que en sus sucesores).

Como muestra del interés de esta observación multibanda, hemos incluido una imagen AVIRIS correspondiente a una incendio forestal que ocurrió en el sur de California en 1999 (fig. 3.41). La imagen recoge diversas bandas espectrales del mismo incendio, mostrando el interés que aporta cada una de ellas en la observación del fenómeno. Mientras en las bandas cortas (azul) se observa principalmente el humo, en el IRC puede observarse con claridad el área recientemente quemada, y en el SWIR las zonas activas. En esta banda la dispersión provocada por el humo es mucho menor que en las más cortas, por lo que es perceptible con claridad el frente de llamas. Aunque para la detección de focos activos sería más recomendable un banda un poco más larga (3,7 μm en lugar de los 2,5 μm que proporciona el AVIRIS), queda patente el interés de esta región del espectro para localizar el avance del fuego.

Además de albergar al sensor Hyperion, conviene indicar que el satélite EO-1 tiene bastante interés para situar las líneas futuras de desarrollo de los sistemas de observación de la Tierra de NASA, ya que resulta un prototipo para validar tecnologías que permitan instalar sensores de menor coste y con un mayor apoyo del sector privado. Este satélite es el primero del programa de la NASA para el nuevo milenio. Incluye un equipo de características muy similares al ETM+, denominado ALI *(Advanced Land Imager)*, aunque con mayor resolución espacial (la banda pancromática cuenta con 10 m), y espectral (9 bandas entre el VIS y el SWIR, si bien elimina el canal térmico), y mejor relación señal-ruido. Está construido con tecnologías más económicas que el ETM+, por lo que puede servir como sustituto de este sensor en misiones futuras.

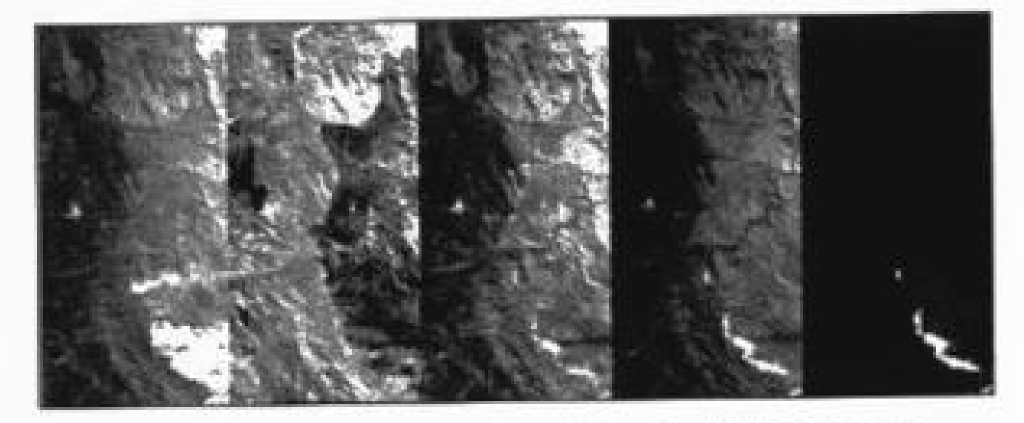


FIG. 3.41. *Imagen AVIRIS de un incendio ocurrido en el condado de San Bernardino (sur de California) el 1 de septiembre de 1999. Las bandas corresponden, de izquierda a derecha, a 0,5 μm, 1 μm, 1,5 μm y 2 μm* (FUENTE: NASA, visibleearth.nasa.gov).

SEGUNDA PARTE

LA INTERPRETACIÓN DE LOS DATOS

CAPÍTULO 4

BASES PARA LA INTERPRETACIÓN DE IMÁGENES DE TELEDETECCIÓN

«Éste es un infeliz que viene perdido y es necesario socorrerle, pues todos los forasteros y pobres son de Zeus y un exiguo don que se les haga le es grato.»

HOMERO, *Odisea*

Como ya señalábamos en la introducción, el objeto de esta obra es facilitar el acceso a una técnica que puede ser muy fructífera en la mejor comprensión de diversos fenómenos ambientales. Por tanto, se ha puesto más el énfasis en la interpretación que en las técnicas para la obtención de las imágenes. Los capítulos previos se dirigen precisamente a facilitar esa interpretación, de tal forma que cada uno pueda extraer información relevante de las imágenes espaciales en su propio ámbito de interés. En este capítulo se presentan algunas ideas introductorias, que pueden ser útiles en el momento de proyectar una aplicación temática a partir de los datos suministrados por sensores espaciales. Parece lógico que antes de abordar la interpretación propiamente dicha se consideren una serie de cuestiones de cara a mejorar la organización de un proyecto que requiera de esta técnica. Los aspectos más destacados hacen referencia al tipo de sensor o de tratamiento más conveniente para la aplicación que se persigue.

En la organización de un proyecto las decisiones se basarán principalmente en dos aspectos: 1) los objetivos del proyecto, y 2) los medios disponibles para su realización. Lógicamente, los objetivos del trabajo orientan la mayor parte de las decisiones consiguientes, como son las relativas al tipo de información necesaria, a su exactitud, escala y nivel de desagregación. Por su parte, los medios disponibles implican un equilibrio entre lo deseable y lo posible, restringiendo el método más idóneo para abordar los objetivos marcados, ya sea en lo que se refiere a las imágenes disponibles para el análisis, ya a los medios para su interpretación (fig. 4.1).

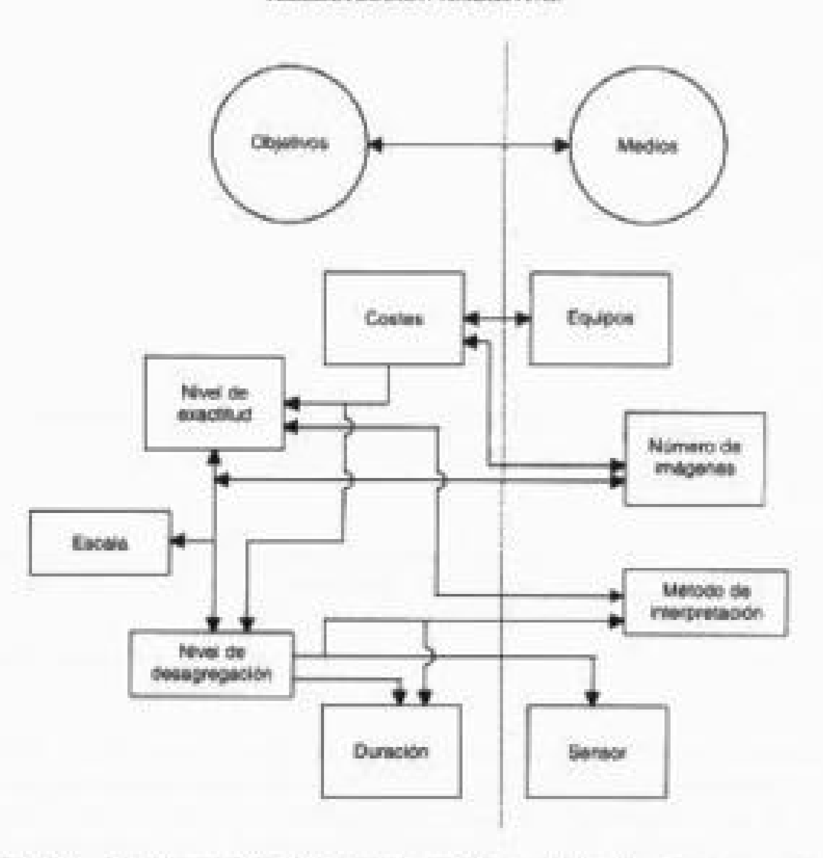


FIG. 4.1. *La interpretación de imágenes en teledetección implica tomar una serie de decisiones que optimicen los objetivos perseguidos en función de los medios disponibles.*

1. Limitaciones para el empleo de la teledetección

1.1. INFORMACIÓN QUE BRINDAN LAS IMÁGENES

Cualquier usuario-novicio de la teledetección debería tener presente que es una técnica con limitaciones, válida para resolver un determinado número de problemas. No es, como se ha concebido en algunos ambientes, una panacea que solucione todas las necesidades de información sobre el medio ambiente que se requieren actualmente. Falsas expectativas pueden conducir a falsas conclusiones, arribando al polo opuesto: esto es, a concebir la teledetección espacial como una técnica más vistosa que eficaz. Para evitar uno y otro extremo, cualquier proyecto de aplicación debería comenzar cuestionándose si esta técnica puede solventar el objetivo marcado, y si la información que ésta ofrece no es obtenible por otros medios más rápidos o económicos.

La respuesta no siempre es sencilla. El rango de aplicaciones de la teledetección está en constante crecimiento, gracias a las innovaciones en los equipos sensores y en los métodos de tratamiento. Sin embargo, parece lógico que un trabajo de aplicación se base sobre un soporte previo, en donde diversos proyectos de investigación hayan demostrado la validez de una determinada metodología. A este respecto, existe ya un buen grupo de estudios en donde la teledetección espacial está reconocida como una fuente primaria de información, como son la cartografía de la cobertura del suelo, estadística agraria, exploración minera, temperatura y componentes del agua, determinación de recursos pesqueros, evaluación de ciertos impactos ambientales y predicción meteorológica, entre otros. Otra serie de aplicaciones se encuentran aún en fase de experimentación, como es el caso de la estimación de biomasa en cultivos, el inventario del volumen de nieve, la detección de contaminantes o los cálculos demográficos. Por último, otros proyectos son aún inviables con los sensores actuales, ya sea por el nivel de precisión que exigen (inventario ganadero o de animales silvestres), ya por falta de la resolución espacial, temporal o espectral necesaria (detección operativa de incendios, detección de aerosoles). En cualquier caso, una inspección a la amplia bibliografía disponible evitará concebir esperanzas irreales y realizar gastos innecesarios.

1.2. EL COSTE DE LA INFORMACIÓN GEOGRÁFICA

Otro aspecto que dificulta el diálogo entre usuarios o potenciales «clientes» de la teledetección es la frecuente percepción en estos últimos de que se trata de una técnica cara, que requiere inversiones elevadas, o implica procedimientos de trabajo que se apartan de los mecanismos de producción ya establecidos. Adquirir una imagen IKONOS, por ejemplo, resulta una fuerte inversión si lo comparamos con adquirir fotografías aéreas de similar escala. Ahora bien, además de que los costes de estas imágenes de alta resolución bajarán en un inmediato futuro —con la llegada de otros sensores de similares prestaciones—, cuando se comparan costes con la fotografía aérea no se consideran los propios de la planificación y ejecución del vuelo, ni lo que supone la oportunidad de tener los datos en un momento determinado y con un formato específico. Algunos autores han planteado comparaciones entre las dos fuentes de información, siendo claramente ventajosa la teledetección cuando nos referimos a espacios suficientemente grandes (Martínez Vega, 1996; O'Connell y Lachman, 2001).

En cualquier caso, aunque la inversión sea objetivamente costosa, no hemos de perder de vista que no disponer de ella puede resultar, a la larga, mucho más caro, pues la falta de información implica decisiones que pueden ser poco adecuadas, mientras una planificación acertada del territorio supone a la larga grandes beneficios, también económicos. Además, y en el caso de la gestión de desastres naturales, la falta de datos puede acentuar las consecuencias catastróficas de estos eventos, anular o hacer ineficaces las medidas de mitigación, y dificultar la recuperación de esos espacios (Baker, 2001).

1.3. EL DIÁLOGO CON LOS USUARIOS

Si la teledetección no ha penetrado con mayor fuerza en muchos ámbitos de la gestión territorial, también puede deberse a que los interesados por esta técnica no hemos sabido resolver satisfactoriamente las necesidades reales de los destinatarios,

bien por falta de capacidad en los sistemas sensores disponibles, bien por no comprender adecuadamente esas necesidades. En el primer caso, estarían aquellas aplicaciones de la teledetección que todavía requieren una mejora en la resolución espacial, espectral o temporal de los sensores para cumplir los requisitos operativos de los gestores. Por ejemplo, para utilizar operativamente la teledetección espacial en las tareas de detección de incendios se requeriría una frecuencia de adquisición de imágenes que sólo proporcionan actualmente los satélites meteorológicos, pero a un nivel de detalle excesivamente grosero. Por tanto, si se plantea emplear esta técnica como alternativa realista a la vigilancia terrestre necesitamos contar con un sistema espacial diseñado *ad hoc* para esta finalidad, que satisfaga las necesidades reales de esta comunidad de usuarios. Ése es el planteamiento del sistema Fuego, que desarrolla la empresa española Insa (www.insa.es/fuego.html), y constituye uno de los pocos ejemplos de sistemas de teledetección diseñados para una aplicación concreta. Otro, bastante obvio, sería la predicción del tiempo, que cuenta desde los años sesenta con satélites específicos. En el futuro, con la reducción de precios de los sistemas sensores y de las plataformas espaciales, pensamos que el diseño de misiones específicas puede hacer de la teledetección una herramienta plenamente operativa en múltiples aplicaciones.

En cuanto a posibles problemas de comunicación con las comunidades de usuarios, se está enfatizando en los últimos años la importancia de implicarlos en cualquier proyecto de investigación y desarrollo, pues facilitan una orientación de gran interés para poner esas tareas en un contexto más realista. No cabe duda de que en muchas ocasiones la falta de interés de los posibles destinatarios por la teledetección puede venir dada por nuestra incapacidad para entender bien sus necesidades, y la consecuente insistencia en ofrecerles productos que no resuelven adecuadamente sus problemas operativos. Por ejemplo, y siguiendo con el ejemplo anterior, los gestores de la prevención y el combate de incendios forestales difícilmente entenderán que les ofrezcamos una cartografía del peligro de incendio exclusivamente a partir de teledetección, cuando nos estamos refiriendo, en el mejor de los casos, a una sola variable relacionada con el peligro (el estado hídrico de la vegetación), dejando a un lado otras variables críticas en el inicio y desarrollo de un incendio, como pueden ser el viento o la humedad relativa del aire que son, hoy por hoy, difícilmente generables a partir de teledetección. Probablemente, sería más fácil que estos usuarios potenciales aceptaran el interés de la técnica si les ofrecemos únicamente lo que podamos generar a partir de las imágenes, subrayando el interés de integrar esa información con la procedente de otras fuentes.

2. Variables y tipos de interpretación

Sintetizando mucho las cosas, puede afirmarse que las imágenes de satélite nos facilitan dos tipos de variables (Jensen, 2000):

— *Primarias*, aquellas que se relacionan directamente con los datos obtenidos por el sensor; esto es, que influyen primariamente en la señal registrada en la imagen.

— *Secundarias* (Jensen las denomina híbridas), que se derivan de las primeras mediante algún tipo de conceptualización.

Las variables primarias son exclusivamente cuantitativas, ya que la señal recogida por el sensor corresponde a una variable numérica (radiancia espectral, altura), que está, a su vez, influida por esas variables biofísicas. Por ejemplo, la temperatura modifica la radiancia emitida en el IRT, por lo que la señal que el sensor recoge en esa banda del espectro será una función de la temperatura y, en definitiva, ésta será extraíble de aquélla (como veremos en cap. 6, apdo. 6.2.4). Lo mismo podemos decir de otras variables que explican directamente la reflectividad o la emitancia de una cubierta (clorofila, contenido de agua, evapotranspiración, composición mineralógica, humedad, etc.). Cuando el sistema de teledetección utiliza otras tecnologías pueden detectarse también variables de posición y altura (a partir de estereo-restitución, de interferometría o de sensores lidar, por ejemplo).

Por su parte, las variables secundarias corresponden a un segundo nivel de abstracción, realizado habitualmente mediante una elaboración de varias de las anteriores. Por ejemplo, podemos deducir el grado de estrés hídrico de las plantas a partir de medir su contenido de agua, de clorofila o temperatura, pero el estrés en sí no se mide directamente. De igual forma, la identificación de una determinada cobertura del suelo viene dada por medir su reflectividad en distintas bandas del espectro, junto a sus propiedades texturales y espaciales (forma, tamaño, etc.).

Esta discusión nos lleva a plantear los distintos tipos de interpretación que pueden aplicarse a una imagen adquirida por teledetección, según el tipo de documento que quiere obtenerse. A nuestro juicio, a partir de una imagen se pueden generar cuatro tipos de productos (fig. 4.2):

1. *Cartografía temática.* Se trataría, en este caso, de asignar cada elemento de la imagen en una categoría homogénea, ya sea mediante interpretación visual o digital. En pocas palabras, este enfoque tiene por objetivo etiquetar cada píxel en la clase temática más apropiada. Ésta ha sido la aplicación más común del análisis de imágenes, en clara herencia de la foto-interpretación clásica. Ya desde los primeros años de vida del sensor Landsat-MSS, las aplicaciones más comunes de estas imágenes se dirigían a obtener el inventario y cartografía de un determinado fenómeno: cobertura del suelo, litologías, tipos de nieve, etc. Suponiendo que la asignación de píxeles a categorías sea correcta, este enfoque presupone que cada píxel es homogéneo —ya que se etiqueta con un sólo valor— y, por tanto, se asume de alguna manera que existen transiciones bruscas en el espacio. Supongamos que un píxel se cataloga como arbolado y el vecino como matorral; lo habitual será que en el terreno ambos cuenten con las dos cubiertas, en mayor o menor proporción, pues los cambios de vegetación son graduales. Aunque los métodos más recientes de clasificación permiten asignaciones múltiples (cap. 7, apdos. 1.6.3 y 2.3.7), es obvio que cualquier intento de agrupación implica una partición más o menos rígida del espacio, con el riesgo que eso lleva consigo en variables muy continuas en el terreno.

2. Un segundo enfoque considera a las imágenes de satélite como una matriz de medidas numéricas de una variable de interés, por lo que podrían utilizarse para obtener una representación espacial de dicha variable (las que hemos denominado primarias), o de alguna relacionada con ella (variables secundarias). Bajo esta óptica, la exploración que realizan los equipos sensores se concibe como un procedimiento para muestrear sistemáticamente una determinada variable de interés ambiental. La densidad del muestreo

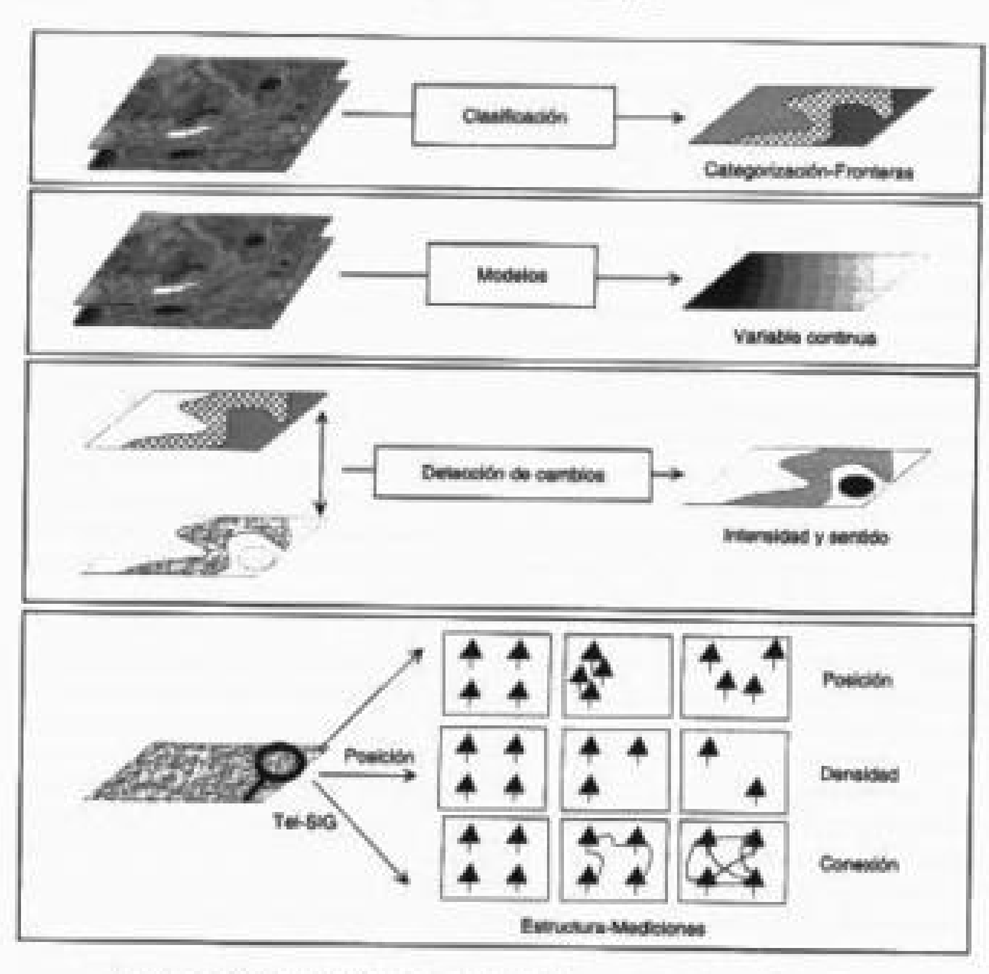


FIG. 4.2. *Tipos de análisis que pueden abordarse en una imagen de satélite.*

vendría marcada por la resolución espacial del sensor (cada cuántos metros tenemos un dato). Aun en el caso de los satélites meteorológicos de peor resolución espacial, ese muestreo es mucho más denso que el que puede realizarse desde sensores terrestres. El caso más evidente es el estudio de la temperatura de la superficie marina. Previamente a la actividad de los satélites oceanográficos sólo se realizaban mediciones en puntos muy distantes (boyas, perfiles a partir de buques), interpolándose esos valores al resto de la superficie marina. Con la observación espacial pueden obtenerse mediciones de la temperatura, la salinidad o la clorofila del agua a intervalos regulares y relativamente cercanos (aproximadamente 1 km en el caso del AVHRR o del Seawifs: fig. 10*), ofreciendo una imagen mucho más certera de la realidad. En este enfoque de interpretación, la teledetección se orienta a generar variables biofísicas, mediante algún modelo que relacione las medidas del sensor (reflectividad, emitancia) con dichas variables (cap. 7, apdo. 1). Obviamente, este enfoque sólo está disponible cuando tenemos información digital y calibrada, esto es cuando hay una relación consistente entre los datos de la imagen y una

variable física determinada (radiancia espectral, ordinariamente). No está disponible, por tanto, con sensores fotográficos, en donde el tono sólo refleja de modo cualitativo la energía detectada originalmente por el sensor.

3. *Determinación de cambios.* Como ya hemos indicado, una de las principales ventajas de la teledetección espacial es su capacidad para seguir fenómenos dinámicos, gracias a la cobertura cíclica que proporcionan. Esta capacidad resulta de gran interés para inventariar ciertos procesos ambientales: crecimiento urbano, desecación de humedales, efectos de incendios o plagas, etc. Bajo esta óptica, el fin del análisis no es tanto establecer fronteras entre categorías, como señalar aquellas zonas de la imagen que han modificado sensiblemente sus rasgos espectrales entre dos o más fechas. Esa detección de cambios podía hacerse sobre imágenes previamente clasificadas o, de modo más habitual, sobre transformaciones de las bandas originales. En este segundo caso, el cambio puede medirse en una escala continua, ya que las imágenes de partida son cuantitativas y por tanto las técnicas aplicadas pueden también serlo (diferencias o cocientes entre fechas, regresión, componentes principales: cap. 7, apdo. 3).

4. Finalmente, las imágenes de satélite pueden también considerarse como una representación del mosaico espacial de un determinado territorio, por lo que servirían asimismo para medir las relaciones geográficas entre las manchas que lo forman. Bajo este punto de vista, la imagen nos permitiría mediar la textura o diversidad espacial de la ocupación del suelo, la forma de las parcelas, sus conexiones espaciales, etc., aprovechando el carácter digital de la imagen (cap. 7, apdo. 4).

3. Organización de un proyecto de teledetección

Supuesto que el objetivo de nuestro trabajo sea abordable a partir de sensores espaciales, deben definirse una serie de aspectos para explicitar el tipo de información y de tratamiento que se aplicará en el proyecto. En este sentido conviene considerar, entre otros aspectos, qué sensor resulta más adecuado para los requisitos solicitados, cuántas imágenes se requieren, de qué fechas, qué métodos de análisis se aplicarán, y qué papel tendrán los trabajos de campo.

3.1. DEFINICIÓN DE OBJETIVOS

La definición de objetivos resulta crucial a la hora de plantear un proyecto de teledetección, ya que los requisitos marcan notablemente las decisiones que habrá que tomar sobre el material más idóneo para conseguirlos (sensor, número de imágenes, fechas, etc.) y la metodología de trabajo.

Resulta frecuente, especialmente en el entorno de la actividad empresarial, que el usuario de la teledetección se vea obligado a organizar un proyecto de trabajo en función de unos objetivos que le vienen dados. Dicho en otras palabras, el intérprete de las imágenes tiene que tomar una serie de decisiones para cumplir unos requisitos emanados de la institución a la que debe presentar ese trabajo, la Administración —en sentido amplio— u otra empresa, habitualmente en forma de pliego de condiciones del proyecto. En esos casos, este epígrafe resultará superfluo, y el lector puede moverse di-

rectamente a los siguientes, ya que poco podrá decidir sobre los objetivos del proyecto. En cambio, si se trata de un proyecto de investigación, en donde comúnmente es el propio intérprete el que plantea las metas a alcanzar, la lectura de estos párrafos puede ayudar a plantear esos objetivos con mayor eficacia. Como criterio general, conviene subrayar la importancia de que los objetivos de un proyecto se adapten a las posibilidades de los datos que se van a emplear en su desarrollo. El comentario puede parecer obvio, pero en la práctica no lo es tanto, ya que en muchas ocasiones se han planteado proyectos de teledetección poco realistas, que no contemplaban las limitaciones inherentes a la técnica o a los sensores específicos que había disponibles en esos momentos. Como antes hemos comentado, algunos usuarios, llevados de un cierto desconocimiento o de un interés comercial poco prudente, han podido vender falsas expectativas respecto a la calidad de la información que ofrecen los sensores remotos, lo que implica una rémora para el desarrollo futuro de esta técnica. Cuando se plantea un proyecto de investigación, su nombre ya lo indica, intentamos validar nuevos métodos, datos o aplicaciones, con una cierta posibilidad de que no conduzcan a avances significativos: a veces se olvida que comprobar que la hipótesis de partida no funciona es tan científico como verificarla. En consecuencia, en estos casos puede aceptarse un margen de incertidumbre y fracaso, pero no sería prudente plantear un proyecto de investigación como una aplicación ya consolidada, obviando los aspectos no resueltos, que van a condicionar notablemente los resultados.

La confusión entre aplicaciones operativas y experimentales puede marginar el empleo de la teledetección en instituciones que de otro modo estarían abiertas a emplear esta técnica. En consecuencia, nos parece muy importante que se planteen unos objetivos realistas, bien fundados sobre bibliografía de referencia, y adaptados a la resolución espacial, espectral y temporal de los sensores que tendremos disponibles. La definición de objetivos hace referencia no sólo al propósito genérico del trabajo (p. ej., realizar un inventario de cultivos), sino también a sus especificaciones: a qué escala, con qué nivel de desagregación, con qué exactitud, en cuánto tiempo, a qué coste..., etc.

3.2. Escala y leyenda de trabajo

La escala y el nivel de desagregación están íntimamente relacionados. Como es lógico, las escalas grandes requerirán leyendas mucho más detalladas que las escalas pequeñas, donde no tendrá sentido intentar distinguir un número elevado de clases: la necesaria generalización de líneas en mapas de pequeña escala exige también una generalización de las categorías cartografiadas.

La escala del trabajo condiciona también la unidad más pequeña de información que se debe incluir en un mapa temático, que suele denominarse mínima unidad cartografiable (MUC). Varios autores recomiendan que la MUC no sea inferior a 4 mm², medidos a escala del mapa (Anderson *et al.*, 1976; Campbell, 1996). De ahí que la escala de trabajo esté directamente relacionada con el tipo de sensor más idóneo para abordar el mismo (Robin, 1998: fig. 4.3). No tendría sentido realizar una cartografía a escala 1:50.000 utilizando el sensor AVHRR del NOAA, pues la MUC sería de, aproximadamente, 2 × 2 cm (1 km² a esa escala). De igual forma, no sería muy razonable abordar un estudio de pequeña escala (p. ej., 1:1.000.000) a partir del sensor Land-

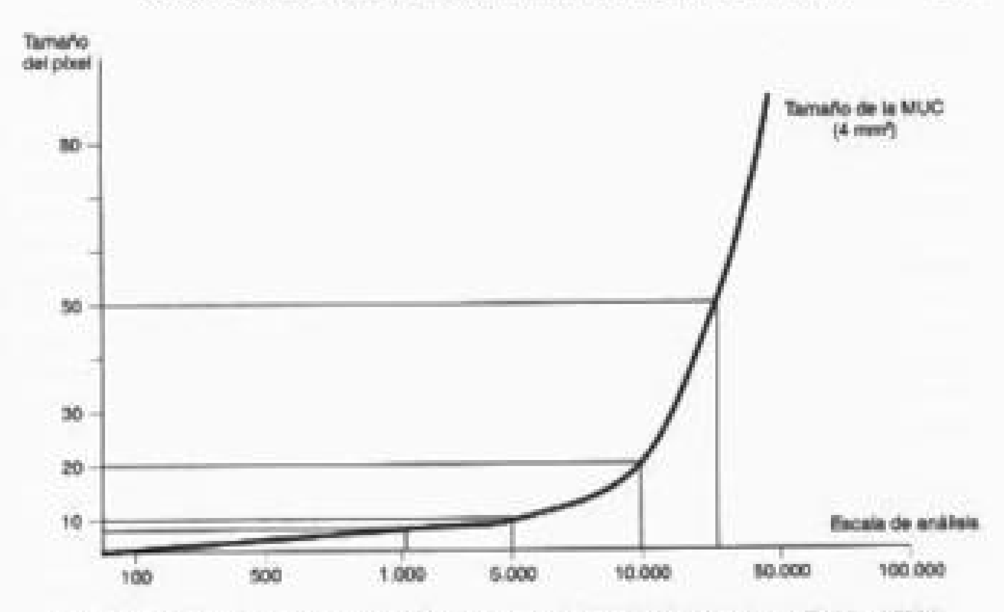


Fig. 4.3. *Relaciones entre resolución y tamaño de la MUC.* (Adaptado de Robin, 1998.)

sat-TM, pues habrían de generalizarse luego los resultados, lo que no justificaría la inversión inicial. De acuerdo con la Asociación Cartográfica Internacional, las escalas límite más idóneas para algunos sensores son (ampliado de López Vizoso, 1989*b*):

NOAA - AVHRR	1:2.000.000
Landsat - MSS	1:200.000
Landsat - TM	1:100.000
Spot - HRV (Pan)	1:50.000
IRS-1C (Pan)	1:25.000
Ikonos (XS)	1:25.000
Ikonos (P)	1:10.000

No conviene confundir la MUC con el tamaño del mínimo objeto que puede observarse en la imagen. Obviamente, aquélla tiene que ser mucho más grande que éste, de lo contrario el riesgo de error aumenta considerablemente. En este sentido conviene distinguir entre los conceptos de identificación y detección, bastante empleados en análisis visual de imágenes (entre otros, puede verse Robin, 1998). La identificación hace referencia al reconocimiento de las características de un determinado objeto, que nos permite caracterizarlo en sus formas y superficies reales, mientras la detección sólo implica determinar su existencia. Lógicamente, la primera tarea requiere mucho más resolución espacial que la segunda, pues sólo será reconocible algo con un tamaño muy superior al del píxel (al menos 5 veces superior, según la mayor parte de los autores), mientras puede ser incluso inferior al tamaño del píxel para ser detectado. Por ejemplo, puede determinarse la presencia de un río en una imagen, incluso si es de anchura inferior a la resolución espacial, gracias al fuerte contraste en la absorción del

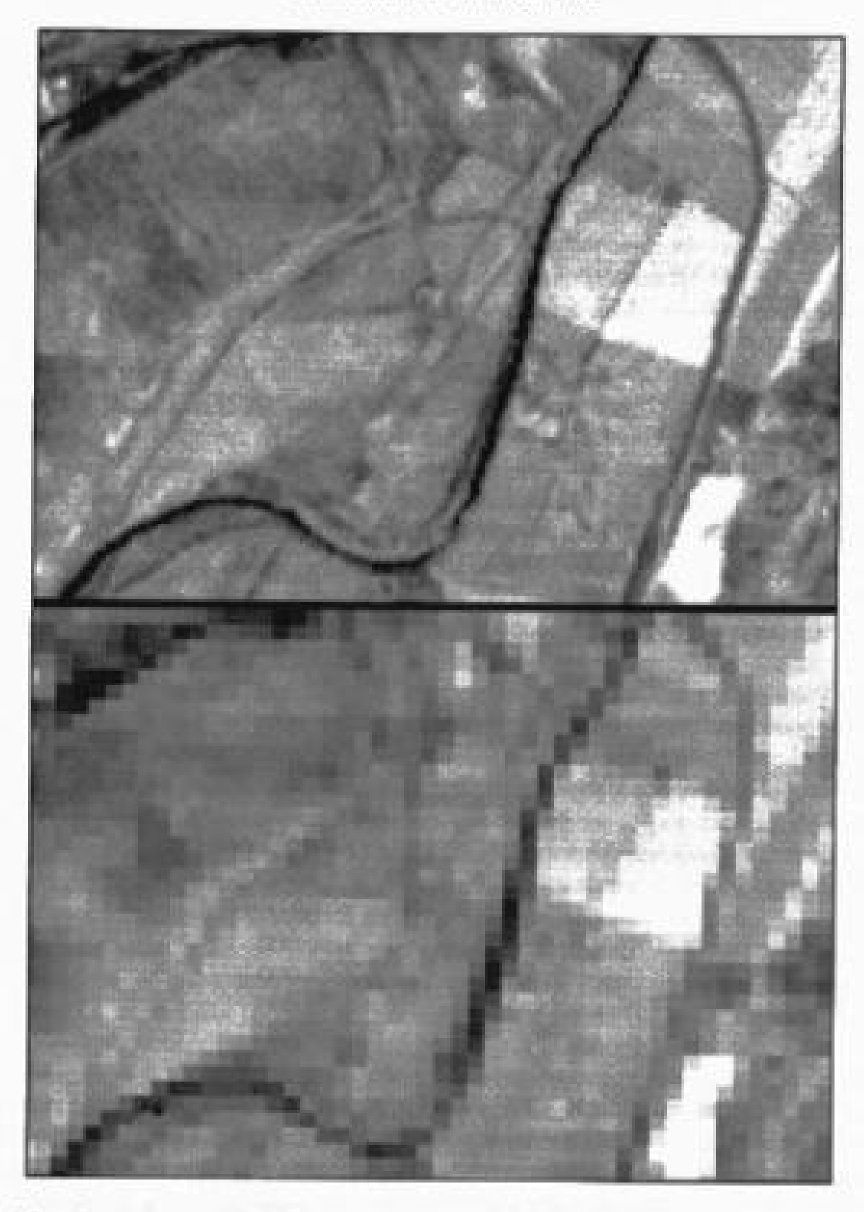


FIG. 4.4. *Dos imágenes del río Henares, en las proximidades de Alcalá, a 15 m de resolución en la parte superior, y a 180 m en la inferior. En la primera puede identificarse el río, en la segunda sólo detectarse.*

agua, que hará bajar la reflectividad de los píxeles por los que discurre. Sabremos que está allí, pero no podremos medir su anchura o forma, que sólo será perceptible a partir de imágenes más precisas (fig. 4.4). En consecuencia, si lo que se pretende es interpretar rasgos específicos de la imagen, su tamaño medio marcará el nivel mínimo de resolución que puede admitirse en una imagen. Por ejemplo, no parece adecuado adquirir

imágenes de un sensor de resolución media para análisis urbano, donde será inevitable contar con alta resolución espacial.

Con la generalización del empleo de imágenes de satélite en distintas aplicaciones cartográficas, va siendo cada vez más frecuente que distintos proyectos temáticos se basen en esta información. Esto nos permite encontrar diversos ejemplos de proyectos cartográficos a distintas escalas realizados a partir de teledetección. Entre ellos, podemos citar desde escalas globales, que cubren todo el planeta, normalmente con resoluciones entre 1 × 1 km y 0,5 × 0,5 grados, y se basan en imágenes NOAA-AVHRR, SPOT-Vegetation o Terra-Modis (Ahern *et al.*, 2001; DeFries y Townshend, 1994), hasta inventarios regionales, con escalas próximas a 1:100.000, que cubren países o continentes, basados en imágenes Landsat-TM o SPOT-HRV (European Commission, 1993). El trabajo de Martínez (1996) analiza diversos proyectos cartográficos a escala global, nacional y regional llevados a cabo con imágenes de satélite en distintos ámbitos geográficos.

En lo que se refiere a la leyenda de la cartografía temática, conviene indicar que no sólo está en función de la escala, sino también de la complejidad del territorio. Como consecuencia, ha sido práctica habitual en algunos inventarios (como, por ejemplo, en la cartografía de ocupación del suelo) emplear una leyenda particular para cada zona de estudio, bien adaptada a las necesidades locales, pero con escasa validez para otros ámbitos. Por ejemplo, hace algunos años tuvimos ocasión de analizar una muestra de 28 trabajos relacionados con la cartografía de ocupación del suelo a partir de teledetección, notando que ninguno presentaba criterios comunes para el establecimiento de la leyenda (Chuvieco, 1985*b*). Las clases más repetidas eran agua —la más fácil de discriminar a partir de sensores espaciales—, área urbanizada, cultivada y forestal, aunque en estas últimas se realizaban múltiples divisiones, según los objetivos específicos del inventario Esta falta de criterios comunes dificulta la generalización de resultados a otros espacios, e invalida cualquier intento de cartografía sistemática del territorio.

En caso de que la leyenda no sea un requisito previo al trabajo (esto es, que no estén fijadas *a priori* las categorías que quieren discriminarse), el intérprete debería cuidar mucho este aspecto, de tal forma que las clases establecidas tengan coherencia entre sí, y con las herramientas que vamos a utilizar en el análisis. En este sentido es especialmente importante que la leyenda no incluya clases que puedan solaparse entre sí, y que recoja toda la variación posible que haya en el área de estudio. En definitiva, que las clases sean mutuamente excluyentes y exhaustivas, propiedades obvias, pero no por ello universalmente respetadas, de cualquier tipología de clasificación. Es frecuente observar que se mezclan criterios a la hora de definir las clases de una determinada leyenda, lo que implicará un cierto margen de aleatoriedad en el proceso. Por ejemplo, la clase matorral en ladera implica mezclar dos temas distintos: cobertura y emplazamiento, y no resulta una categorización exhaustiva, ya que no podríamos asignar el matorral que se presente en otros ámbitos geomorfológicos. Las clases pinar de repoblación y pinar sobre calizas no son excluyentes, pues puede haber lógicamente pinar de repoblación situado sobre calizas.

De cara a establecer leyendas más robustas se han planteado diversas propuestas de clasificación, que incorporan un carácter jerárquico, eso permite adaptar distintos niveles de detalle (desagregación de clases) en función de la calidad de los datos disponibles.

Un ejemplo de este tipo de leyendas es la diseñada por el *U.S. Geological Survey* en 1976, específicamente concebida para el empleo de sensores remotos (Anderson *et al.*, 1976). Se trataba de una leyenda de uso y ocupación del suelo, organizada en cuatro niveles jerárquicos, cada uno de los cuales se pretendía obtener a partir de diversos medios de teledetección: imágenes de satélite para el nivel más general, y fotografía aérea de gran escala, en combinación con el trabajo de campo, para las clases más detalladas. Esta clasificación resultaba flexible, podía aplicarse a espacios muy contrastados, y garantizaba la integración entre campos afines de inventario medioambiental. El principal problema que presentaba, a nuestro juicio, era la inclusión en el mismo esquema de clases de uso y de ocupación del suelo,[1] lo que origina ambigüedad en el proceso de clasificación. Por ejemplo, un mismo objeto o grupo de ellos podrían asignarse a varias categorías de acuerdo a su consideración como uso u ocupación: canteras (uso) y roquedo desnudo (ocupación), o dehesa (uso) y pastizal arbolado (ocupación). Como es lógico, los sistemas de teledetección sólo permiten realizar cartografía de la ocupación del suelo, ya que la señal detectada por el sensor corresponde a los objetos que aparecen en la superficie terrestre, y no necesariamente al uso al que se destinan. El uso podría ser deducido por el intérprete en algunos casos (por ejemplo, a partir de una cubierta de cultivos se infiere fácilmente un uso agrícola), pero no en otros (a partir de una cubierta de matorral no puede deducirse si el uso es ganadero o cinegético).

Pese a este problema, el trabajo de Anderson y colaboradores ha sido enormemente fructífero, y base para otros intentos similares. Éste es el caso de la leyenda diseñada para el programa *CORINE-Land Cover* (tabla 4.1), realizada específicamente para trabajar con imágenes de satélite. Este proyecto forma parte de las bases de datos que se han generado para la Agencia Europea de Medio ambiente, y pretendía inventariar la ocupación del suelo de los países miembros a escala 1:100.000 a partir de interpretación visual (auxiliada con análisis digital) de imágenes de satélite. El proyecto, al que más tarde se unieron los países de la antigua Europea oriental y algunos del norte de África, puede calificarse como una de las primeras aplicaciones operativas de la teledetección espacial (descontando, naturalmente, las meteorológicas), ya que está concebido para generar un inventario sistemático de la cobertura del suelo de un amplio territorio (European Commission, 1993; López Vizoso, 1989*a*; Moreira y Fernández-Palacios, 1995; Mounsey, 1991). La leyenda incluye también un enfoque jerárquico, de tal manera que cada país pueda enriquecer un esquema común de partida en función de sus propias necesidades, a la vez que se mantiene una coherencia entre países para asegurar que los resultados sean comparables. En estos momentos se está iniciando la actualización del proyecto *Land Cover*, con datos del año 2000 para España. Frente a la exclusiva interpretación visual de la primera cartografía, en este segundo inventario se están empleando algunas herramientas de interpretación digital (Smits y Annoni, 1999).

Otros intentos similares a los del programa *Corine-Land Cover* se han planteado en otros países, aunque tal vez no con la trascendencia internacional de este proyecto.

1. Siguiendo la terminología anglosajona, distinguimos entre uso y ocupación del suelo (*land use* y *land cover*, respectivamente), según nos refiramos a la actividad humana sobre el territorio o a las cubiertas que aparecen sobre él (Chuvieco, 1985*b*).

TABLA 4.1. *Clasificación propuesta para el proyecto de Ocupación del suelo de España (CORINE-Land Cover)**

1. *Superficies edificadas e infraestructuras:*
   - 1.1. Zonas urbanas.
   - 1.2. Zonas industriales, comerciales y de transporte.
   - 1.3. Zonas de extracción minera, vertederos y de construcción.
   - 1.4. Zonas verdes y espacios de recreo.
2. *Zonas agrícolas:*
   - 2.1. Tierras de labor anual.
   - 2.2. Cultivos permanentes.
   - 2.3. Praderas.
   - 2.4. Zonas agrícolas heterogéneas.
3. *Zonas forestales, con vegetación natural y espacios abiertos:*
   - 3.1. Bosques.
   - 3.2. Espacios de vegetación arbustiva y/o herbácea.
   - 3.3. Espacios abiertos con poca o nula vegetación.
4. *Zonas húmedas:*
   - 4.1. Humedales continentales.
   - 4.2. Humedales marítimos.
5. *Superficies de agua:*
   - 5.1. Aguas continentales.
   - 5.2. Aguas marinas.

* Sólo se recogen los dos primeros niveles de la clasificación. En la adaptación española de la leyenda comunitaria se llega, en algunas cubiertas, hasta los cinco niveles.

Por el carácter global, basta finalmente con citar el mapa de cobertura del suelo de todo el planeta realizado por uno de los grupos de trabajo del programa IGBP (*International Geosphere Biosphere Program*) a partir de imágenes NOAA-AVHRR (DeFries y Townshend, 1994). Actualmente se está actualizando esta cartografía a partir de imágenes MODIS y vegetación.

Sea una u otra la lista de categorías finalmente empleada, conviene recordar que el nivel de detalle que ofrece la leyenda se relaciona estrechamente con el riesgo de error, por cuanto es altamente probable que cualquier subdivisión implique separar categorías muy similares espectralmente. Caso de que esa ulterior división no sea abordable a partir de las imágenes o del método de interpretación propuesto, deberá el usuario ajustar alguno de los dos parámetros: bien hacia una leyenda más generalista, bien hacia imágenes o métodos de tratamiento más refinados.

3.3. SELECCIÓN DE LOS MATERIALES

Una vez establecida leyenda y escala de trabajo puede abordarse la elección del material que constituirá la base del estudio. A este respecto conviene considerar varios elementos: tipo de sensor, fecha de adquisición, soporte de las imágenes y material auxiliar.

3.3.1. *Tipo de sensor*

Como ya se ha indicado, el tipo de sensor más conveniente depende de los objetivos y el nivel de precisión requerido en el proyecto. Lógicamente, los inventarios globales habrán de partir de sensores de baja resolución espacial (tipo NOAA-AVHRR o Meteosat), mientras los de mayor escala se basarán en sensores que ofrecen una resolución espacial más detallada (IRS o IKONOS).

No obstante, en otros casos la resolución espacial resulta secundaria frente a la temporal o espectral. Por ejemplo, si el fenómeno estudiado es muy dinámico en el tiempo, como sería el caso de la detección de incendios forestales o la predicción de cosechas, convendrá acudir a sensores de alta resolución temporal (como el AVHRR), aun sacrificando fiabilidad espacial. En otras ocasiones, la dimensión espectral será dominante, por lo que convendrá acudir a sensores que ofrezcan información en aquellas bandas del espectro donde se manifieste con mayor claridad el fenómeno de interés. Un buen ejemplo de esta idea sería la exploración minera a partir de sensores hiperespectrales (Kruse *et al.*, 1993*a*). En definitiva, la resolución espacial es un elemento muy destacado para seleccionar el sensor más conveniente en cada caso, pero no debe ser el único a considerar (cap. 3, apdo. 2).

3.3.2. *Fecha de adquisición*

La fecha más conveniente para seleccionar la imagen está en estrecha relación con el tipo de fenómeno a estudiar. Lógicamente, el momento más idóneo de adquisición será aquel en que mejor se discrimine dicho fenómeno, frente a otros de similar comportamiento espectral. Un análisis geomorfológico probablemente requiera una fecha invernal, al ser mayor el efecto de sombras y, por tanto, más clara la detección de rasgos del relieve. Por el contrario, el inventario de algunos cultivos de regadíos sólo puede realizarse en los meses de verano, julio y agosto en nuestras latitudes, cuando se encuentran en el suelo (naturalmente, otros cultivos de regadío, con otros calendarios fenológicos, requerirán otras fechas más apropiadas, caso del viñedo, que convendrá mejor observarlo a fines de septiembre). En ocasiones resultará necesario acudir a varias fechas para abordar el estudio: por ejemplo, para seguir el ritmo de crecimiento de un determinado cultivo, o para estudiar los cambios entre dos momentos críticos. En estas situaciones conviene construir un calendario fenológico de esa cubierta —y de las que ofrezcan un parecido comportamiento espectral—, con objeto de seleccionar las fechas en donde su comportamiento sea más específico del resto.

Cuando en estos trabajos de cartografía de la cubierta vegetal se disponga de un presupuesto escaso puede ser preciso seleccionar una sola fecha, que maximice la separación entre todas las cubiertas. En ese caso, la elección más conveniente será una imagen adquirida en el verano, pues en ese momento es máxima la radiancia media percibida por el sensor, como consecuencia del mayor ángulo de elevación solar. Además, en el caso de nuestro clima mediterráneo, la estación estival coincide con la época de menor nubosidad y precipitación, lo que facilita la selección de imágenes de este período.

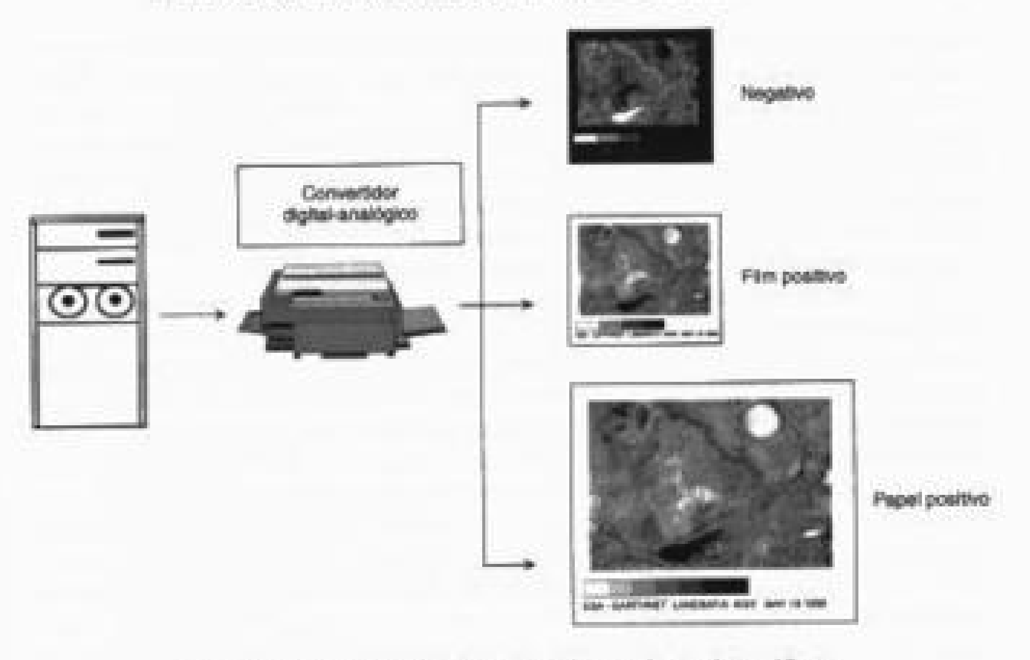


FIG. 4.5. *Soportes más habituales de los productos fotográficos.*

3.3.3. *Soporte de las imágenes*

El soporte sobre el que puede realizarse la interpretación depende del tipo de tratamiento que se aplique. En caso de que se opte por el análisis visual se requiere resolver tres aspectos: 1) soporte material de la imagen, 2) escala, y 3) número de bandas y combinación de bandas seleccionada.[2]

En lo que se refiere al primer aspecto, hasta hace muy pocos años las entidades distribuidoras de imágenes ofrecían tres opciones. Las imágenes podían pedirse en película negativo, en película positivo o en papel (fig. 4.5). Todavía estos formatos pueden encontrarse para imágenes históricas o para misiones fotográficas, como algunas del *Space Shuttle*. Actualmente, casi todas las empresas que comercializan imágenes de satélite lo hacen exclusivamente en formato digital: queda, por tanto, al usuario la labor de convertir esos valores numéricos en tonos de gris o color si lo que pretende es realizar una interpretación visual de la imagen.

Para los documentos más antiguos, baste indicar que los negativos permiten ampliaciones muy versátiles, ajustándose a la escala deseada, pero la calidad de la copia que se obtenga luego en papel es inferior a la adquirida directamente en este soporte. El film positivo es muy útil para reproducción fotográfica e impresión de la imagen, especialmente cuando se trata de composiciones coloreadas de 3 bandas. Por último,

2. Actualmente, cada vez es más frecuente realizar la interpretación visual sobre el propio monitor de visualización, digitizando directamente los polígonos identificados por el intérprete. En ese caso, el soporte de la imagen será la consola, la escala será variable, en función del nivel de magnificación empleado, y la combinación de bandas puede modificarse fácilmente por el intérprete.

los productos que facilitaban las agencias distribuidoras en papel garantizaban una interpretación directa de alta calidad, pero resultaba rígida la escala y no admitía copias sucesivas. Cuando se trata de composiciones en color, a partir de los negativos de cada banda pueden obtenerse tantas combinaciones como requiere el intérprete, mientras el film positivo o papel debía solicitarse ya con una determinada combinación de bandas. Naturalmente, ahora pueden generarse productos en papel a partir de la información digital, mucho mejor adaptados a las necesidades del intérprete, gracias a la creciente disponibilidad de trazadores gráficos en color de amplio formato.

En cuanto al soporte de la información digital, hace algunos años lo más común eran las cintas compatibles con ordenador (CCT), que eran el único medio viable de almacenar un volumen importante de datos. Actualmente las tecnologías magnéticas han dejado paso a las ópticas y, aunque se siguen utilizando cintas de cartucho (predominantemente las Exabyte) para copias de seguridad, cada vez resulta más extendido el empleo del CD-ROM, que resulta más compacto, fiable y económico, además de disponerse de lectores y grabadores de consumo generalizado. Recientemente se han introducido los grabadores de DVD *(Digital Video Disk)*, que puede ser un soporte alternativo para la distribución masiva de datos, si bien las imágenes comerciales actualmente disponibles no requieren un almacenamiento superior a la capacidad de un CD-ROM. También será cada vez más frecuente la distribución de imágenes a través de Internet, facilitando una reducción en los costes y mayor rapidez en el envío.

3.4. Decisión sobre el método de análisis: ¿tratamiento visual o digital?

Como ya se comentó más arriba, las imágenes son adquiridas en formato numérico, gracias a una conversión analógico-digital realizada a bordo del satélite. Por tanto, el tratamiento digital resulta la opción de análisis más inmediata. Ahora bien, esos valores digitales también pueden convertirse a intensidades de brillo o color, con lo que pueden generarse productos cuasi-fotográficos, susceptibles de interpretación visual.

En consecuencia, las imágenes pueden interpretarse digital o visualmente. Cabe preguntarse cuál de los dos resulta más idóneo para explotar adecuadamente el flujo de datos que la teledetección espacial ofrece. La respuesta no resulta sencilla. Simplificando un poco las cosas, pueden señalarse varios aspectos que conviene tener en cuenta antes de tomar una decisión en uno u otro sentido: 1) medios económicos y humanos disponibles, 2) rapidez y exactitud exigida, 3) tipo y continuidad de las tareas, 4) homogeneidad de la superficie analizada (fig. 4.6).

La disponibilidad de medios marca el primer criterio de decisión. En muchas ocasiones se asume que cualquier trabajo en teledetección espacial exige una considerable inversión de partida, por lo que se obvia una técnica que podría ser muy útil aun en situaciones de modesto presupuesto. En definitiva, apenas se considera que el análisis visual no requiere inversiones económicas importantes y puede garantizar un nivel de precisión suficiente para una determinada aplicación. Por ejemplo, el coste por unidad de superficie de una imagen en falso color es considerablemente inferior al de la fotografía aérea, y puede ofrecer una exactitud adecuada (superior al 80 %) para un proyecto de escalas medias o de semi-detalle (menores a 1:50.000). Si se pretende realizar





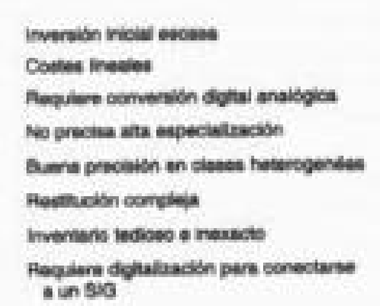


FIG. 4.6. *Ventajas e inconvenientes del análisis visual frente al digital en la interpretación de imágenes.*

una cartografía de la ocupación del suelo a esta escala, la imagen de satélite puede salvar costes y reducir notablemente el tiempo de tratamiento frente a la fotografía aérea, que ofrece un detalle tal vez excesivo para la escala final del mapa (Chuvieco y Martínez Vega, 1990). Además, conviene considerar que varios organismos han publicado estos últimos años coberturas de imágenes de distintas zonas del país (Martínez Vega, 1997). Por ejemplo, el Instituto Geográfico Nacional distribuye orto-imágenes en papel de toda España a diversas escalas, y a una fracción del coste que tienen originalmente. Si la fecha de la adquisición es adecuada para nuestro trabajo, ése será un punto de partida muy conveniente.

En situaciones de presupuesto más desahogado puede abordarse el tratamiento digital de imágenes. El apoyo del ordenador, en principio, garantiza un tratamiento más rápido, económico y, en principio, más certero, pero requiere una mayor inversión inicial, pese a que los equipos y programas informáticos que permiten el tratamiento de las imágenes han reducido en los últimos años sensiblemente sus costes.

Esta inversión inicial hace referencia también al entrenamiento previo del intérprete. El análisis visual emplea claves de identificación similares a la foto-interpretación clásica (tono, textura, tamaño, localización, forma, etc.), por lo que no requiere un entrenamiento previo muy especializado, si bien, como es lógico, precisa una notable agudeza visual y mental, así como la debida experiencia, para obtener resultados brillantes. El tratamiento digital, por su parte, requiere una buena base estadística, co-

nocimiento de sistemas informáticos y lenguajes de programación. Estos componentes no suelen formar parte de los curricula vigentes en las ciencias de la Tierra, por lo que puede resultar complejo el acceso al tratamiento digital para personas provenientes de esos campos de aplicación, aunque conviene considerar que esa base estadística e informática es sólo un medio para mejorar la interpretación, y no un fin en sí mismo.

En pocas palabras, el tratamiento digital requiere mayor inversión económica y entrenamiento que el análisis visual. Como contrapartida, proporciona mayor versatilidad, rapidez y exactitud. No obstante, tales ventajas no son absolutas, sino muy dependientes de la configuración del equipo disponible, del entrenamiento del intérprete y de la complejidad del área de estudio. Por ejemplo, la velocidad de proceso está en función del equipo disponible, por lo que no puede afirmarse que todo tratamiento digital sea más rápido que el visual. El tratamiento digital basado exclusivamente sobre un ordenador personal, sobre imágenes de alta resolución y aplicado a zonas muy amplias, puede resultar bastante lento, por el importante volumen de datos a procesar. La misma zona puede ser interpretada visualmente en menos tiempo, siempre que la escala sea pequeña y no se requiera una leyenda excesivamente pormenorizada.

En cuanto a la exactitud, también ha de matizarse la superioridad del tratamiento digital. Varios autores han comprobado la complejidad de clasificar digitalmente cubiertas que ofrecen una gran heterogeneidad espacial. El caso de las áreas urbanas es el más claro a este respecto (Atkinson *et al.*, 1985; Toll, 1984). Se trata de zonas en donde se mezclan tejados, aceras, asfalto, jardines y espacios abiertos o deportivos. Esta complejidad puede identificarse visualmente gracias a criterios muy difícilmente traducibles a la clasificación digital: localización, textura, tamaño, formas, etc., por lo que la interpretación visual ofrecerá, en este caso, mayor exactitud que la digital. En otras categorías, la relación resulta contraria, ya que el ojo humano no es capaz de detectar variaciones tonales que sí son diferenciables numéricamente (humedales, transiciones de vegetación, distintos cultivos...).

Otro elemento a tener en cuenta para elegir la intepretación visual o digital se refiere al tipo y continuidad de las tareas requeridas en el proyecto. Si el estudio sólo precisa un croquis de interpretación y no una plasmación cartográfica, la interpretación visual no ofrece inconvenientes. Ahora bien, si se pretende obtener un mapa deben transferirse todas las líneas que definen las distintas cubiertas a la cartografía base, lo cual resulta muy tedioso y poco preciso, si no se utilizan restituidores de cierta fiabilidad. El tratamiento digital, por el contrario, permite realizar este proceso con gran rapidez y —salvo terrenos muy accidentados— elevada precisión, gracias a las técnicas de corrección geométrica de la imagen (cap. 6, apdo. 6.3). Lógicamente, estas correcciones digitales pueden aplicarse como paso previo a la interpretación visual, y de hecho la mayor parte de los organismos distribuidores de imágenes incluyen la opción de solicitar las imágenes ya georreferenciadas, si bien son más costosas que las originales y, en ocasiones, no ofrecen elevada exactitud (dependerá si esa corrección se basa sólo en modelos orbitales o se enriquece con puntos de control). Asimismo ya están corregidas geométricamente las imágenes que se distribuyen como series cartográficas (a veces se utiliza el término espacio-mapas o carto-imágenes).

Otras operaciones que resultan muy beneficiadas con el tratamiento digital son el inventario de resultados y su integración con otras variables geográficas. El inventario

resulta muy tedioso en interpretación visual, pues es necesario planimetrar todas las superficies incluidas en cada tipo de cubierta. En el caso del tratamiento digital basta realizar un cálculo de frecuencias —esto es, del número de píxeles incluidos en cada clase—, para conocer la superficie ocupada por cada una de ellas, por cuanto sabemos la equivalencia superficial de cada píxel. Naturalmente, en caso de que se opte por la interpretación visual y digitización simultánea en pantalla, las imágenes ya estarán georreferenciadas, por lo que el inventario se obtiene también casi de modo inmediato.

Respecto a la posibilidad de combinar los resultados del análisis con otro tipo de variables territoriales: suelos, hidrografía o pendientes, la integración manual convencional resultaba muy compleja (técnica de superponibles), mientras la asistida por ordenador supone un proceso relativamente sencillo, en el marco de los denominados SIG (cap. 9). La entrada de información en estos sistemas requiere una previa digitización para el caso del análisis visual, mientras resulta un proceso bastante inmediato en tratamiento digital —especialmente si el SIG almacena la información en formato ráster—, puesto que las imágenes ya se encuentran en soporte numérico. Como antes indicamos, si la interpretación visual se realiza sobre pantalla, la digitización es inmediata y, por tanto, su integración en un SIG, y el acceso a las funciones de análisis que estos sistemas proporcionan.

En resumen, y siguiendo nuestra opinión particular, ambos métodos de trabajo se complementan, y pueden emplearse integradamente. El tratamiento digital permite realizar operaciones complejas, muy costosas o inaccesibles al análisis visual. Garantiza una clasificación más rápida de la zona de estudio, manteniendo una coherencia en la asignación de áreas vecinas a dos categorías, a la vez que permite generar la distribución espacial de variables biofísicas (temperatura, clorofila en el agua, etc.), y simplifica la determinación de cambios temporales. Por su parte, el análisis visual es una buena alternativa para actualizar cartografía existente, identificar clases heterogéneas o realizar inventarios a escalas medias o de semi-detalle. Auxilia a la clasificación digital, aislando sectores de potencial confusión sobre la imagen, o estratificando algunos sectores de la imagen para aplicarles tratamientos específicos. El tratamiento digital supone una fuerte inversión de entrada, pero los costes van disminuyendo al aumentar la superficie analizada. Por el contrario, los costes del análisis visual son lineales, suponiendo una pequeña inversión de partida (Chuvieco y Martínez Vega, 1990). Con estos planteamientos, la inversión en equipos informáticos parece imprescindible en tres casos: 1) cuando el objeto de estudio no sea abordable mediante análisis visual, 2) cuando se pretendan obtener modelos biofísicos, detección de cambios o medición numérica de la estructura del territorio, y 3) cuando se pretenda introducir los resultados en un SIG.

Asumiendo que los equipos de tratamiento digital están disponibles, la interpretación de la imagen puede realizarse con criterios visuales y digitales. En este marco, podríamos aprovechar la potencia de análisis de la interpretación visual (incluyendo criterios de contexto, textura, formas complejos que puede emplear un intérprete humano), así como la flexibilidad y potencia del tratamiento digital (georreferenciando la imagen, mejorando su aspecto visual, digitizando información en pantalla, etc.). En definitiva, podemos actualmente hablar de una fotointerpretación asistida por ordenador, que elimina diversas fases de la interpretación visual clásica (restitución, inventario). A la vez, esa interacción visual con el intérprete permitirá resolver algunos pro-

blemas del tratamiento digital, que encuentra notables dificultades para automatizar la interpretación de ciertos rasgos de la imagen (algunas nubes, áreas urbanas...), que son bastante obvios al análisis visual.

4. Fases en la interpretación

Las aplicaciones de la teledetección espacial son muy numerosas, por lo que resulta complejo establecer un marco general, que pueda ser válido para todas ellas. No obstante, y aun a riesgo de caer en la simplicidad, puede ser conveniente introducir algunas ideas sobre el proceso de trabajo con este tipo de imágenes. No será difícil que cada usuario pueda ajustar este esquema a sus propios intereses.

El proceso propuesto contempla las siguientes fases (fig. 4.7):

1. Definición expresa y concreta de objetivos, señalando las limitaciones que se presentan, ya sean derivadas del área de estudio (complejidad), ya de los requisitos del

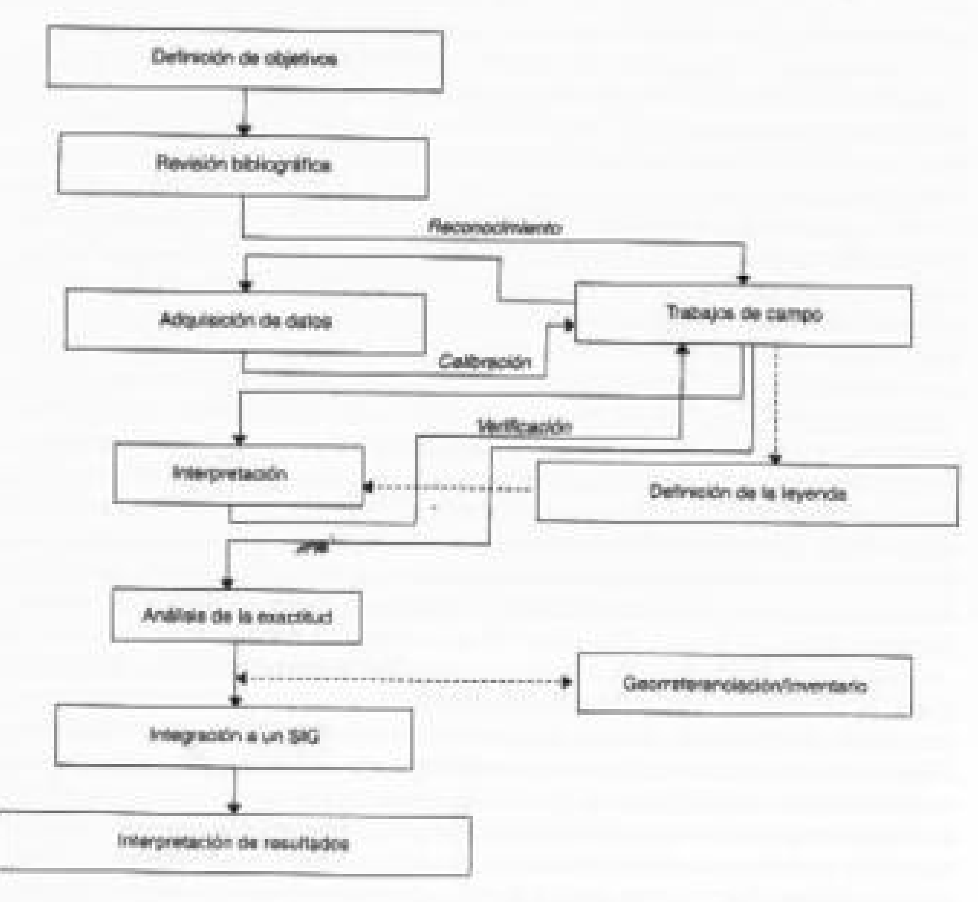


FIG. 4.7. *Fases que incluye un proyecto de clasificación de imágenes.*

trabajo (duración del proyecto, coste máximo, categorías temáticas a discriminar, etc.) o ya de los medios disponibles.

2. Revisión bibliográfica y propuesta de método. En función de la literatura consultada sobre el tema, podrán plantearse las alternativas metodológicas más razonables. Un estudio bibliográfico resulta vital para orientar el proceso de análisis, optimizando las decisiones futuras.

3. Trabajos de campo preparatorios y acopio de información auxiliar. En este primer contacto, los trabajos de campo permiten familiarizar al intérprete con la zona objeto de estudio, estudiar sus rasgos medioambientales y humanos. Si se trata de una aplicación relacionada con la cubierta vegetal, resulta conveniente elaborar un calendario fenológico de las especies de interés con objeto de seleccionar la fecha o fechas más apropiadas para adquirir la imagen. En esta fase pueden incluirse las medidas a realizar con radiómetros de campo —que permiten caracterizar espectralmente la cubierta y seleccionar el sensor y las bandas más apropiadas para discriminarla—, así como el acopio del material auxiliar necesario para la posterior interpretación de la imagen.

4. Selección de la información de partida: sensor y fecha (o fechas) más conveniente, número de imágenes, soporte, etc.

5. En caso de que la leyenda no sea un requisito del proyecto (esto es, que ya estén marcadas las categorías que necesitan discriminarse), el usuario deberá plantear una leyenda adecuada de trabajo, basada sobre las características de la zona y las posibilidades que brinda el sensor seleccionado.

6. Trabajos de campo de calibración. Una vez adquiridas las imágenes, esta segunda fase de campo sirve para familiarizar al intérprete con la imagen, caracterizando sobre ella la variación de las distintas clases señaladas en la fase anterior. Esta fase debería realizarse simultáneamente a la adquisición de la imagen, con objeto de evitar cualquier ruido posterior en el análisis que pueda deberse a variación de las condiciones entre terreno e imagen. Caso de que el trabajo pretenda generar una variable cuantitativa, aquí deberíamos realizar las medidas de campo de esa variable para calibrar y luego validar el modelo (caso de que sea empírico), o validarlo sólo (caso de que sea teórico). Las campañas de medición en terreno (fig. 4.8) resultan claves para poder establecer posteriormente relaciones cuantitativas con los datos de la imagen.

7. Interpretación de estas cubiertas, ya sea a través del análisis visual, ya del tratamiento digital, extendiendo al resto de la imagen la experiencia acumulada en el muestreo de campo realizado previamente.

8. Revisión de campo, para la verificación de resultados, de acuerdo al porcentaje de fiabilidad requerido y a la tasa de error tolerable en el muestreo. Esta fase puede también simultanearse con la (6) siempre que no se empleen las mismas áreas para clasificar/calibrar y para verificar/validar la imagen (ver cap. 8).

9. Restitución. Una vez obtenidos unos resultados suficientemente fiables, se trata de otorgar validez cartográfica a los resultados; esto es, que el documento obtenido pueda superponerse sobre la cartografía base. Esta restitución puede ser digital o analógica, en función del método seguido en el análisis, si bien, como hemos indicado, también puede realizarse interpretación visual a partir de imágenes ya corregidas cartográficamente.

10. Obtención de resultados e integración en un SIG. Esto supone la digitiza-



FIG. 4.8. *La obtención de datos sobre el terreno resulta clave para calibrar modelos de interpretación de imágenes.*

ción de la interpretación visual o, en caso de tratamiento digital, las modificaciones precisas para que se ajuste perfectamente a la cartografía convencional disponible (cambios de proyección y/o resolución).

11. Inventario. Aquí se trata de cuantificar la extensión superficial de cada una de las categorías, una vez se hallen representadas sobre un mapa de escala conocida. Al igual que en la fase anterior, el procedimiento variará de acuerdo al método de análisis: conteo de frecuencias (digital), o planimetría (visual), si bien, en caso de que se hayan digitizado previamente los polígonos identificados visualmente, el inventario también se obtiene automáticamente.

12. Interpretación de la cartografía resultante, poniéndola en relación con las variables humanas y del medio físico que afectan al área de estudio.

Como puede observarse, este esquema está bastante centrado en aquellas aplicaciones que persigan elaborar una cartografía temática a partir de la teledetección, pero podría también adaptarse a la generación de variables continuas, la detección de cambios o el análisis del patrón espacial a partir de las imágenes.

CAPÍTULO 5

INTERPRETACIÓN VISUAL DE IMÁGENES

«El fanático comienza por no pedir razones y acaba por no tolerarlas.»

IZRAIL METTER, *La quinta esquina*

Ya en el capítulo anterior se comentaron los rasgos principales de esta labor interpretativa. Allí se presentaban las dos alternativas para analizar los datos adquiridos por el sensor: 1) abordar una interpretación visual, y 2) optar por el tratamiento digital de la imagen. En el presente apartado se estudia con más profundidad la interpretación visual de imágenes, para pasar, en los dos próximos, a exponer los principios del tratamiento digital. La mayor parte de los comentarios incluidos en este capítulo se refieren a imágenes adquiridas por diversos sensores de la familia Landsat. El amplio rango de aplicaciones que ofrecen y la extensión de su empleo justifican esta elección. No obstante, la mayor parte de las ideas aquí expresadas pueden fácilmente aplicarse a imágenes adquiridas por otros sensores, especialmente a aquellos comprendidos en el dominio óptico, y de similar resolución a los incluidos en el programa Landsat (SPOT-HRV, MOS-MESSR, IRS-LISS, etc.)

1. Familiarización con imágenes analógicas

1.1. INFORMACIÓN INCLUIDA EN LOS PRODUCTOS FOTOGRÁFICOS

Una interpretación detallada de imágenes requiere tener en cuenta los principales rasgos de su adquisición, así como de los tratamientos que puedan haber abordado las antenas receptoras. Hasta hace unos años, lo habitual en la interpretación visual de imágenes era partir de los productos fotográficos que ofrecían las distintas agencias de distribución de imágenes. Actualmente, muy pocas disponen de esta opción, centrándose el análisis visual en la interpretación sobre pantalla o sobre imágenes impresas. En ambos casos, la información auxiliar vendrá dada en el archivo digital de cabecera.

No obstante, a efectos históricos, nos parece conveniente seguir citando las ano-

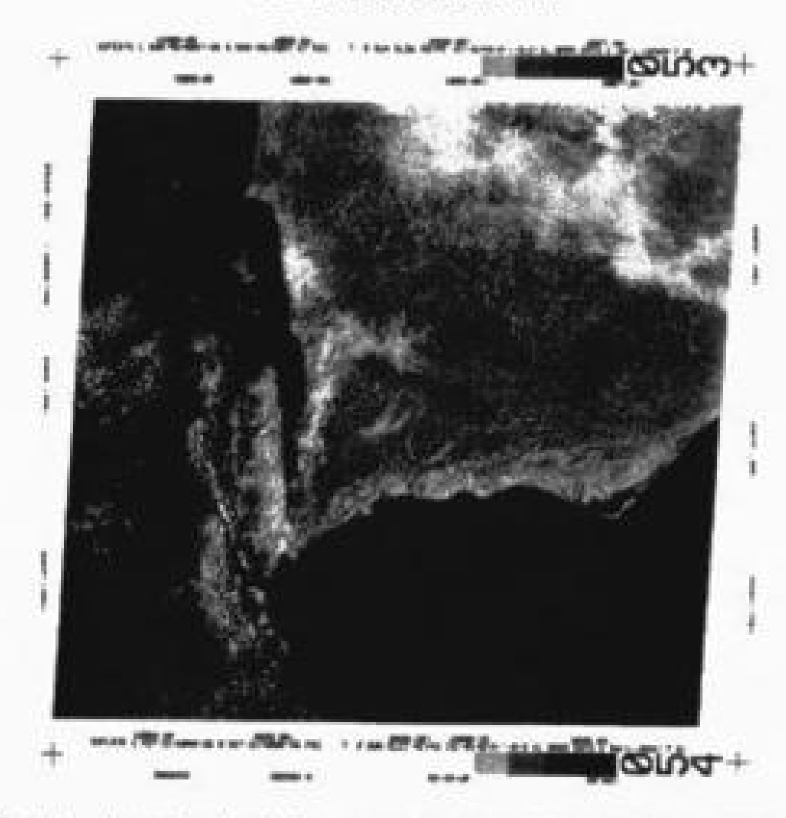


FIG. 5.1. *Imagen Landsat de la costa portuguesa en el formato original de NASA.* (Cortesía: R. Núñez.)

taciones que incluían los productos fotográficos. Para las primeras imágenes procesadas por la NASA, y distribuidas por el *EROS Data Center (U.S. Geological Survey)*, se incluía la siguiente información auxiliar (fig. 5.1):

— Fecha de adquisición (2 de febrero de 1975).
— Coordenadas del centro de la imagen (37° 21' Norte y 8° 26' Este).
— Coordenadas del punto nadir (punto de intersección entre la superficie terrestre y una perpendicular desde el centro de adquisición).
— Sensor y banda empleada (MSS, banda 7).
— Ángulo de elevación solar, medido entre la horizontal y la dirección de los rayos solares (26°).
— Ángulo acimutal, medido desde el norte geográfico y en el sentido de las agujas del reloj (143°).
— Datos del procesado (correcciones aplicadas, escala, proyección, compresión o no de los datos, etc.).
— Agencia y proyecto (NASA ERTS).
— Código de identificación de la escena (número de satélite, días transcurridos desde el lanzamiento, hora, minutos y segundos de la adquisición: E - 2011 - 10331 - 7 01).

— Marcas fiduciarias en las esquinas para localizar el nadir, cruzándolas de dos a dos en diagonal.

Debajo de estos datos se situaba una escala de grises, con objeto de comprobar la calidad de la reproducción.

En los años ochenta, otras agencias espaciales comenzaron a encargarse de la distribución de imágenes. Para toda Europa, la Agencia Espacial Europea (ESA) se responsabilizó de la recepción de los datos, gracias a sus estaciones de Fucino, Tromsø y Maspalomas, mientras el programa EARTHNET se hacía cargo de la red distribuidora. Como consecuencia de esto se modifican las anotaciones en los productos fotográficos del satélite Landsat, ajustándose al siguiente esquema (fig. 5.2):

— Escala de grises en el borde inferior de la imagen.
— Por debajo de ella se incluía información sobre la fecha de adquisición, número de satélite, código de identificación de la escena y banda. En el caso de la figura 5.2, la imagen se adquirió el 29 de enero de 1982 por el satélite Landsat-2, la escena se reconoce por los números 217 (órbita) y 032 (fila), y corresponde a la banda 5. En el margen derecho se sitúa el centro y fecha de tratamiento (Telespazio, 26 de mayo de 1982).
— Marcas fiduciarias.

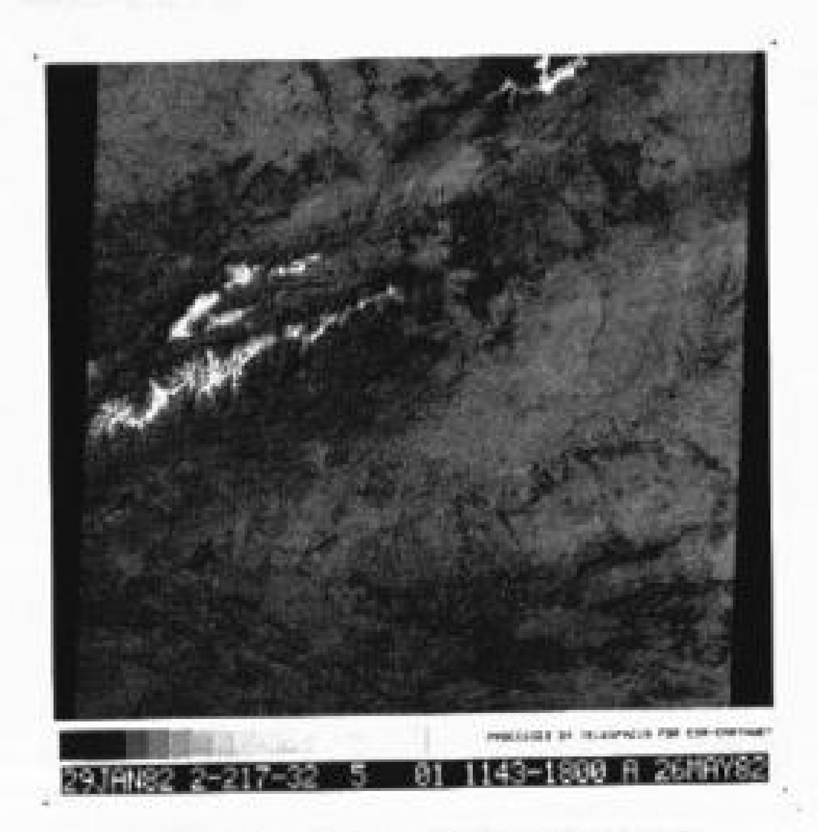


FIG. 5.2. *Imagen Landsat en el formato original de la ESA.*

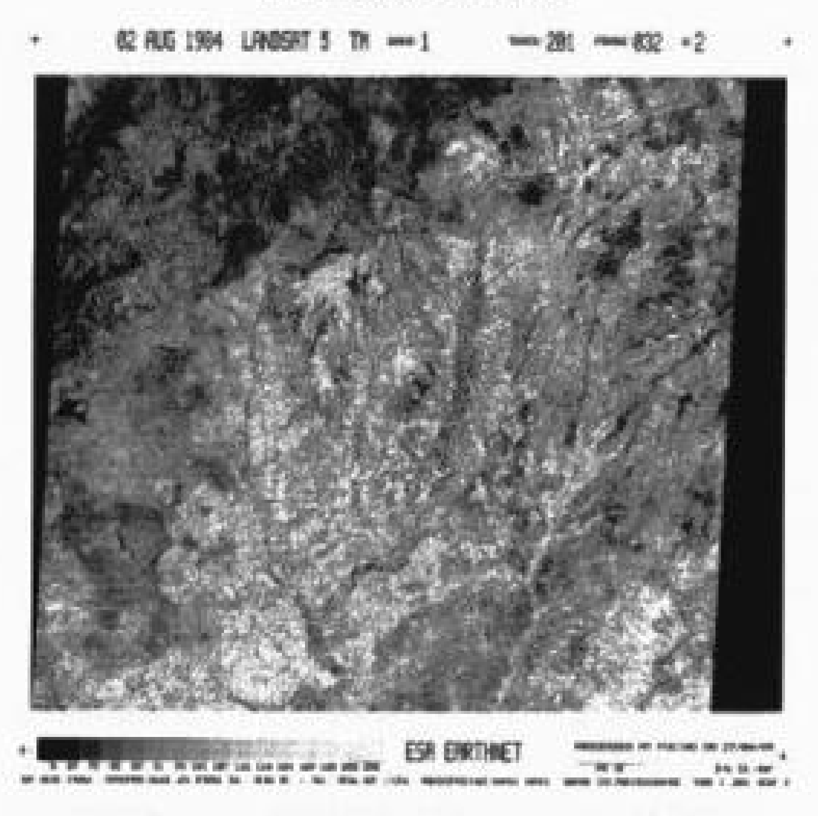


FIG. 5.3. *Imagen Landsat-TM en el formato posterior de la ESA.*

A partir del lanzamiento de los Landsat-4 y 5, se vuelve a modificar la información auxiliar que incluyen los productos fotográficos, enriqueciéndose notablemente frente al anterior formato. Desde ese momento, la red europea EARTHNET recogía los siguientes datos (fig. 5.3):

— En la cabecera del negativo se señalan los datos más importantes de la adquisición: fecha, satélite, sensor, número de banda, código de la escena y, en su caso, número de cuadrante. En el caso de la figura 5.3 se trata de una imagen adquirida el 2 de agosto de 1984, por el satélite Landsat-5, sensor TM *(Thematic Mapper)*, correspondiente a la banda 1, traza 201, fila 032, cuadrante 2.[1]

— En el borde inferior aparece la escala de grises (indicando, además, el valor digital al que corresponde cada intensidad), centro y fecha de proceso y escala gráfica.

— Por fin, la última línea del negativo incluye algunos datos auxiliares, como son la fecha de adquisición, coordenadas del centro de la escena, ángulo de elevación y acimut solar, nivel de corrección radiométrica y geométrica, e identificación de la escena, en el código NASA y en el sistema europeo.

— Marcas fiduciarias.

1. Los cuadrantes se numeran de izquierda a derecha, y de arriba abajo.

1.2. Identificación de algunos rasgos geográficos sobre la imagen

Una primera forma de familiarizarse con las imágenes es compararlas con una fuente cartográfica convencional. Este ejercicio puede abordarse en varias fases. En la primera, apoyándose en un mapa de similar escala, pueden situarse los embalses y cursos de agua más importantes de la zona. A partir de ellos, una segunda inspección de la imagen permite identificar aspectos humanos del territorio, como son las ciudades más importantes y las principales vías de comunicación. Los accidentes montañosos se identificarán en una tercera fase, puesto que se trata de aspectos representados más abstractamente en el mapa y, por tanto, de difícil delimitación. Masas de vegetación o rasgos efímeros relacionados con la imagen (como, por ejemplo, incendios o agentes contaminantes) podrán interpretarse en una última fase, puesto que rara vez vendrán recogidos en el mapa. Este ejercicio puede realizarse a partir de las carto-imágenes que producen distintos centros cartográficos (Instituto Geográfico Nacional, por ejemplo).

Esta primera familiarización sirve de preámbulo para considerar los principales criterios que se utilizan para interpretar visualmente una imagen. Muchos de ellos son comunes a la fotointerpretación clásica de fotogramas aéreos.

2. Criterios para la interpretación visual

Como ya indicamos, una de las principales ventajas del análisis visual sobre el digital es su capacidad para incorporar a la interpretación de la imagen criterios complejos. Mientras el tratamiento digital se basa, casi exclusivamente, sobre la intensidad radiométrica de cada píxel —en las distintas bandas utilizadas para la interpretación—, el análisis visual puede utilizar otros elementos, como son la textura, estructura, emplazamiento o disposición, muy difíciles de definir en términos digitales, aunque se esté trabajando intensamente en esta línea, como luego tendremos ocasión de analizar.

Estos criterios nos permiten discriminar categorías con un comportamiento espectral parejo, aunque con un significado temático bien distinto. Por ejemplo, algunos cultivos en regadío suelen ofrecer una respuesta espectral muy parecida a los parques urbanos, ya que ambas cubiertas están formadas por las mismas o similares especies vegetales. Sin embargo, su significado temático es claramente distinto, y así debe incluirse en la cartografía final. Digitalmente la distinción es compleja, pues los valores numéricos de ambas cubiertas son muy similares. Ahora bien, basta incorporar un criterio visual sencillo, como es el contexto geográfico, para separarlas.

Entre las pautas visuales manejadas en teledetección espacial, algunas son comunes con la fotografía aérea —tono, textura, estructura, sombras, contexto, etc.—, otras son más propias de las imágenes espaciales, principalmente en lo que atañe a la dimensión multi-espectral y multi-temporal de las observaciones, severamente limitada en fotografía aérea. Un último grupo corresponde a criterios tradicionales en foto-interpretación que rara vez resultan accesibles en imágenes espaciales, como es el caso de la cobertura estereoscópica, tan vital para estudios del relieve. En cualquier caso, ya sean nuevos o tradicionales, los criterios visuales deben manejarse con cierta precaución en imágenes de satélite, por cuanto las escalas de trabajo y la geometría de adquisición son distintas a las empleadas en fotografía aérea. Según vayan disponién-

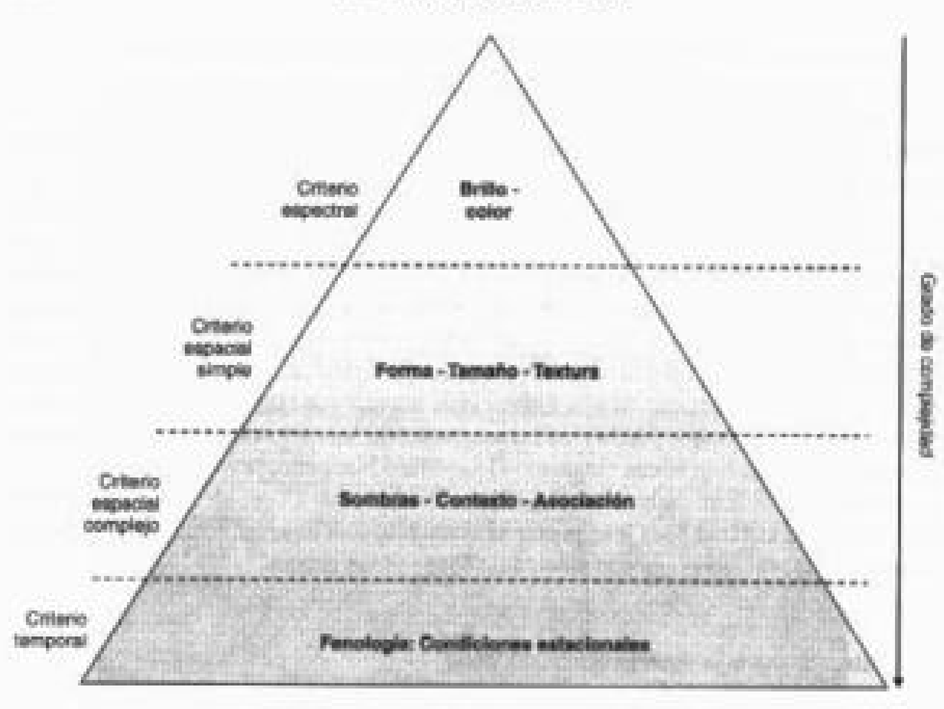


FIG. 5.4. *Organización jerárquica de los criterios de interpretación visual.* (Adaptado de European Commission, 1993.)

dose de imágenes de mayor resolución, estas diferencias se irán atenuando, hasta convertirse prácticamente en inexistentes.

Conviene tener en cuenta que esos criterios se utilizan de modo integrado, en claves visuales complejas. Varios autores han sugerido clasificar esos criterios en una escala jerárquica, en función de su grado de complejidad y de las variables que se consideran (fig. 5.4: European Commission, 1993). El brillo y color serían los criterios más elementales, pues caracterizan espectralmente a una cubierta. La forma, tamaño, y textura tienen que ver con las propiedades espaciales de los objetos. La sombra y emplazamiento, con su relación a los objetos circundantes. Finalmente, la dimensión temporal hace referencia a la evolución estacional de las cubiertas. A continuación revisaremos con detalle los criterios de interpretación visual más utilizados.

2.1. BRILLO

El brillo hace referencia a la intensidad de energía recibida por el sensor para una determinada banda del espectro. En un producto fotográfico, los píxeles con tonos oscuros indican aquellas áreas sobre las que el sensor detectó una débil radiancia, mientras las zonas claras son producto de una mayor intensidad. En otras palabras, el brillo se relaciona estrechamente con el comportamiento espectral de las distintas cubiertas, para la banda particular del espectro sobre la que se trabaje.

Puesto que la energía reflejada desde una cubierta varía en distintas longitudes de onda, su brillo característico también variará en imágenes adquiridas para diversas bandas del espectro. Como ya vimos en el capítulo 2, una superficie ocupada por vegetación vigorosa presentará una alta absortividad en las bandas visibles del espectro, especialmente en el azul y rojo, como consecuencia de la acción de los pigmentos de la hoja en esas longitudes de onda. En consecuencia, en las imágenes adquiridas sobre esas bandas aparecerá en gris oscuro. Por el contrario, se mostrará en grises claros si la imagen corresponde al infrarrojo cercano, por cuanto, en esa región del espectro, la hoja sana ofrece una elevada reflectividad. En consecuencia, para interpretar los brillos que ofrece la imagen se ha de tener presente el comportamiento espectral de las distintas cubiertas de interés. De otra forma, el intérprete puede entrenarse a reconocer mecánicamente algunas categorías, pero no alcanzará a comprender plenamente las razones de las diferencias tonales que observa.

Un intérprete avezado podrá reconocer múltiples categorías por el contraste de brillo en distintas bandas del espectro. Como hemos visto, la vegetación tiende a ofrecer tonos oscuros en las bandas visibles y muy claros en el infrarrojo cercano, mientras el agua presenta tonos oscuros en ambas, los suelos descubiertos ofrecen tonos blancos en las dos, y las áreas urbanas grises medios en ambas (fig. 5.5). Al tratarse de una imagen de primavera (Madrid 00), además de los jardines urbanos, aparecen como manchas de vegetación sana sectores de pastizales o en expectativa de construcción. Una mayor experiencia permite seleccionar las bandas más idóneas para reconocer determinados rasgos de interés: modelos de drenaje y morfología (infrarrojo cercano), trazado urbano (verde-rojo), turbidez en el agua (azul), delimitación tierra/agua (infrarrojo cercano), vegetación (rojo e infrarrojo cercano).

El brillo es uno de los principales criterios de interpretación visual. Ahora bien, el número de intensidades de gris que podemos distinguir sobre la imagen está limitado por nuestra propia percepción visual y el soporte físico utilizado para visualizar (papel o película). En consecuencia, la representación fotográfica de una imagen siempre supone una pérdida considerable de la sensibilidad radiométrica del sensor. De los 256 niveles de brillo —o, si se prefiere, de tonos de gris— que habitualmente facilitan los sensores espaciales (8 bits por píxel), la representación visual de esos datos sólo nos permite discriminar un número de niveles de gris mucho menor (64 en el mejor de los casos). Atendiendo sólo a este criterio, por tanto, el análisis visual sería menos preciso que el digital, ya que parte de lo que el sensor distingue nosotros no podemos diferenciarlo. Habitualmente en fotointerpretación convencional las diferencias de brillo se observan en una sola banda, ya que la mayor parte son pancromáticas. En el caso de las imágenes de satélite, la observación del brillo se realiza simultáneamente en varias bandas, lo que nos facilitará un reconocimiento más certero de algunas cubiertas.

2.2. COLOR

Varios autores han puesto de manifiesto que el ojo humano es más sensible a las variaciones cromáticas que a la intensidad luminosa (Barret y Curtis, 1999*a*). Si a esto añadimos el aumento de información que supone la mezcla de varias bandas del espectro, fácilmente se comprende que el color resulta un elemento básico en la interpretación visual de imágenes.

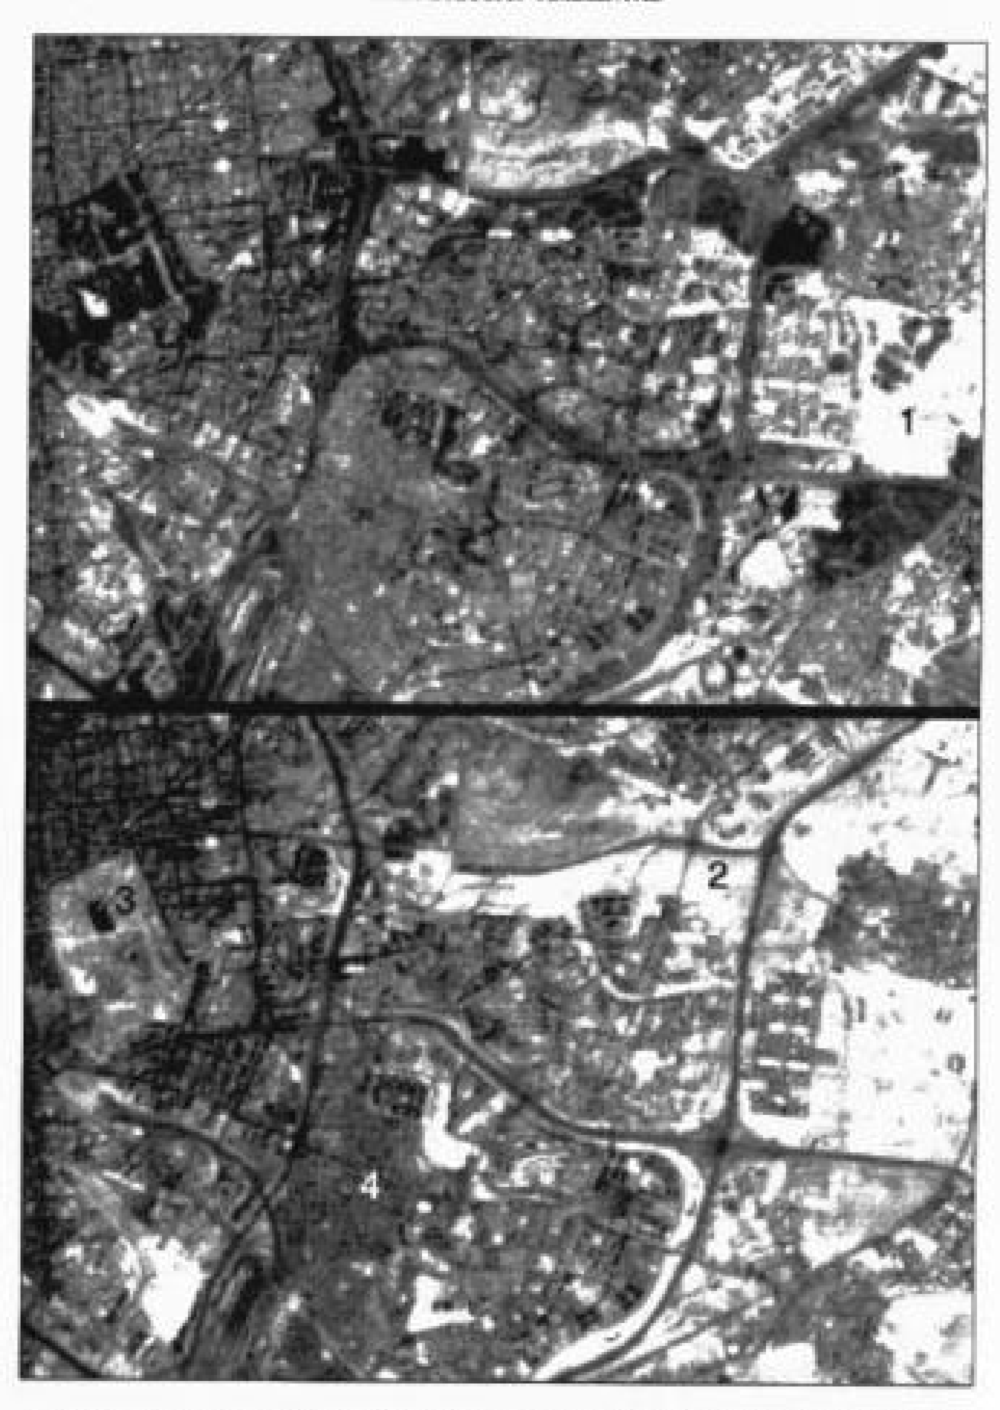


FIG. 5.5. *Variación del brillo en dos bandas en la imagen Madrid00: (1) Suelos descubiertos; (2) Vegetación sana; (3) Agua, (4) Áreas urbanas. La imagen superior corresponde a la banda roja (ETM3) y la inferior al infrarrojo cercano (ETM4).*

Como es bien sabido, el color que aprecian nuestros ojos es fruto de la reflectividad selectiva de los objetos a distintas longitudes de onda. Aquellas superficies con alta reflectividad en el azul, y baja en el resto, aparecen con ese color, mientras ofrecen un tinte rojo si absorben las longitudes cortas y reflejan las largas. Nuestro ojo sólo percibe las longitudes de onda comprendidas entre 0,4 y 0,7 μm, separando la energía recibida en tres componentes de acuerdo a la sensibilidad espectral de nuestras células sensoras. Esos tres componentes son los denominados colores primarios: rojo, verde y azul (RVA), a partir de los cuales puede reconstruirse cualquier otro color del arco iris.

Una impresión similar al color que nosotros percibimos puede obtenerse cuando combinamos las bandas espectrales RVA, aplicando a cada una de ellas los tres colores primarios, en ese mismo orden. Esa asignación «natural» puede modificarse a voluntad del intérprete, asignado los colores primarios RVA a tres bandas espectrales cualquiera, en el orden que se estime más oportuno (fig. 11*). Obviamente, cuando no seleccione las bandas espectrales RVA, sino otras cualesquiera, el color resultante no será con el que nosotros percibimos los objetos (lo que llamamos «color natural»), sino que los colores nos resultarán artificiales, de ahí que suele denominarse a estas composiciones «falso color». Esas composiciones coloreadas no se ajustan a los colores que aprecian nuestros sentidos, pero pueden ser —como, de hecho, suele ocurrir— más interesantes desde el punto de vista de la interpretación temática de la imagen.

Independientemente de las bandas que se incluyan en la composición, conviene considerar algunos aspectos sobre el proceso que permite obtener esas composiciones en color. La mezcla de tres bandas espectrales en una composición en color puede conseguirse de acuerdo a dos procesos, denominados aditivo y sustractivo. En el proceso aditivo, cualquier color se obtiene por suma de los tres colores elementales: azul, verde y rojo. La suma de dos colores primarios permite lograr un color complementario: azul + verde = cian; azul + rojo = magenta, y verde + rojo = amarillo, mientras los tres suman el blanco (fig. 5.6*a*). Por el contrario, el proceso sustractivo se basa en la absorción de la luz que ejercen los colores complementarios: el cian absorbe la luz roja, el magenta absorbe el verde y el amarillo el azul. Los tres en combinación suponen, por tanto, el negro (fig. 5.6*b*).

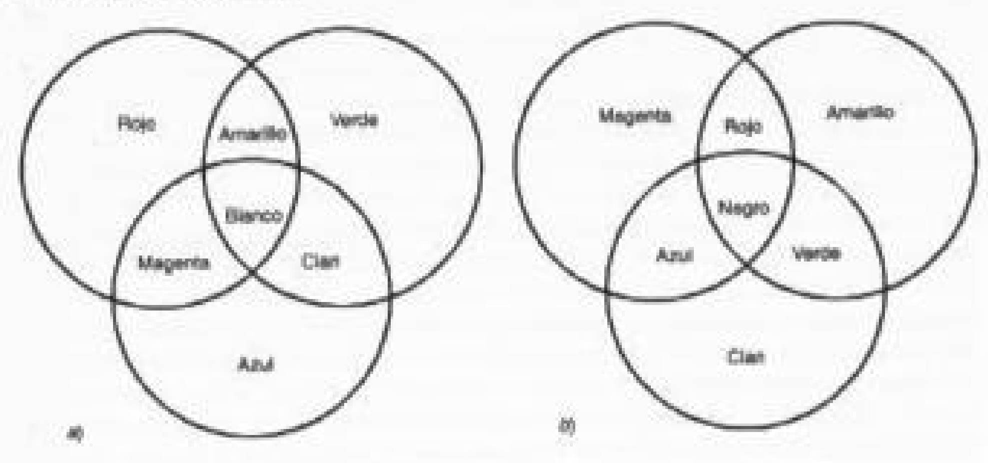


FIG. 5.6. *Procesos de formación del color: a) aditivo, b) sustractivo.*

El proceso aditivo es el utilizado en los sistemas electrónicos de visualización, cuando la imagen se representa sobre un monitor. Éste es el proceso habitual en un equipo de tratamiento digital de imágenes. Por su parte, el proceso sustractivo se emplea en la reproducción mecánica del color, típica de las artes gráficas. Por tanto, cuando se pretenda imprimir una imagen resulta preciso aplicar a cada banda uno de los colores complementarios. Por ejemplo, para obtener una composición en falso color debe aplicarse a las bandas del espectro IRC, R, V los colores complementarios amarillo, magenta y cian, respectivamente. Si, por el contrario, se requiere visualizar esa imagen sobre un monitor, el orden será rojo, verde y azul, para las mismas bandas.

Entre las múltiples combinaciones de color que se han empleado en análisis visual, la más destacada sin duda es la denominada infrarrojo color. Se obtiene desplazando hacia longitudes más largas las bandas del espectro visible, sustituyendo la composición de bandas R, V y A, por la correspondiente al IRC, R y V (fig. 12*a). Su profuso empleo se relaciona con la resolución espectral de la mayor parte de los sensores espaciales. Desde el inicio de la serie Landsat se han venido distribuyendo imágenes con esta composición en color, ya que el sensor MSS incluía información de estas bandas del espectro, así como otros sensores posteriores, como el SPOT-HRV o el IRS-LISS, exclusivamente hasta hace pocos años, por lo que sigue siendo una composición multibanda bastante común.

De cara a facilitar su interpretación puede ser conveniente incluir una simple clave de color, con objeto de familiarizar al intérprete con este tipo de representaciones. Las tonalidades más habituales en ella se corresponden con las siguientes cubiertas (Tindal, 1978):

— *Rojo-magenta*. Denota vegetación vigorosa, como cultivos regados, prados de montaña o bosques de caducifolias en imágenes de verano, y cultivos herbáceos de secano en imágenes de primavera. El estudio detallado de la intensidad y saturación del rojo permite identificar diversas cubiertas vegetales, así como estimar su ciclo de crecimiento y vigor.

— *Rosa*. Muestra áreas vegetales menos densas y/o vegetación en temprano estado de crecimiento. Las áreas suburbanas en torno a las grandes ciudades, con sus pequeños jardines y árboles diseminados, aparecen a veces en ese color.

— *Blanco*. Áreas de escasa o nula vegetación pero de máxima reflectividad: nubes, arenas, depósitos salinos, canteras, suelos desnudos, nieve.

— *Azul oscuro a negro*. Superficies cubiertas total o parcialmente por agua: ríos, canales, lagos, embalses. En zonas volcánicas, los tonos negros pueden asimismo identificar flujos de lava.

— *Gris a azul metálico*. Ciudades o áreas pobladas, si bien puede asimismo tratarse de roquedo desnudo.

— *Marrón*. Vegetación arbustiva, muy variable en función de la densidad y del tono del sustrato. Los tonos más oscuros indican presencia de materiales paleozoicos (pizarras), mientras los matorrales calcícolas, menos densos normalmente, ofrecen una coloración más clara.

— *Beige-dorado*. Identifica zonas de transición: prados secos, frecuentemente asociados con el matorral ralo.

Cuando se comenzaron a adquirir imágenes del sensor TM se abrió la posibilidad de diseñar nuevas composiciones, como la correspondiente al color natural (R, V, A), mientras sus nuevas bandas en el SWIR e IRT ampliaron notablemente las posibilidades de obtener composiciones en color. Con motivo de ello, varios autores han intentado establecer algún indicador, más o menos objetivo, que ayude a seleccionar las bandas más idóneas para una composición en color. Los criterios más estudiados son los de tipo estadístico: análisis de componentes principales, índice óptimo de máxima variación, y obtención de los ejes del elipsoide de variación (cap. 6, apdo. 5.2).

En el terreno del análisis visual, también se han efectuado algunos ensayos para identificar la composición de color que ofrece una mejor discriminación de cubiertas. Se parte de seleccionar intérpretes con distintos grados de experiencia, para cuantificar el número de cubiertas que discriminan adecuadamente en distintas composiciones de color (Benson y Degloria, 1984; Trolier y Philipson, 1986). En estos tests, y para el caso del Landsat-TM (o ETM+), las combinaciones más puntuadas incluyen una banda del espectro visible, otra del infrarrojo cercano y otra del medio. El orden habitual es aplicar el color rojo al IRC, el verde al SWIR o al R, y el azul al R o V (fig. 12*). Estos resultados son muy similares a los obtenidos por otros autores mediante técnicas estadísticas (Hord, 1986). A tenor de este resultado, el proyecto de cartografía de ocupación del suelo de España (dentro del programa europeo CORINE-*Land Cover*) seleccionó la composición TM 4/5/3 (IRC, SWIR, R) como base para la interpretación visual de imágenes. Para objetivos parciales puede ser interesante considerar otro tipo de combinaciones coloreadas. A partir de imágenes TM se ha comprobado la eficacia de la composición formada por las bandas 7/4/1, para detectar zonas quemadas, de la integrada por las bandas 7/4/3 para discriminación de cultivos en regadío o zonas encharcadas, y de la constituida por las bandas 7/3/1 para aplicaciones oceanográficas. Pese al interés de estas composiciones, sigue vigente el papel protagonista de la combinación en infrarrojo color convencional (IRC, R, V).

En la fig. 12* aparecen diversas composiciones coloreadas sobre la imagen (torrel00), que permiten analizar el interés de considerar distintas bandas para interpretar unos u otros rasgos de la imagen. En términos generales puede afirmarse que el color natural ofrece un escaso contraste, presentando tonos verde-oscuros para la vegetación y pardos para las zonas urbanas y suelos descubiertos. La discriminación de la cobertura vegetal es mucho más evidente en el infrarrojo color convencional (IRC,R,V) y en el mejorado (IRC, SWIR, R). En ambos casos, la vegetación más vigorosa aparece en tonos de rojo, ya que a este cañón de color se asigna el IRC. En tonos marrón-ocre aparecen las áreas cubiertas por perennifolios, dependiendo de la época del año en que esté tomada la imagen. Asimismo, los pastizales pueden aparecer en tonos de rojo (en primavera) o en tonos verdosos, si se trata de imágenes de verano. En la combinación IRC, SWIR, R, además, resulta algo más evidente el área edificada, y contrasta mejor la vegetación natural de la que acompaña a las áreas residenciales.

Cuando se cambia el orden de la asignación de colores, lógicamente la leyenda de color antes comentada deja de tener sentido, ya que las tonalidades resultantes serán diferentes. Por ejemplo, si modificamos el infrarrojo color mejorado (IRC, SWIR, R), asignando el cañón de color verde al IRC y el R al SWIR, la vegetación más vigorosa aparece en tonos de verde, en lugar de en tonos de rojo. Este criterio es el empleado por el Instituto Geográfico Nacional para publicar su serie de imágenes de toda España,

sobre la base de facilitar al intérprete poco experimentado —acostumbrado a ver la vegetación en tonos de verde— el análisis de la imagen. En ocasiones se denomina esta composición en color como «seudo-color natural».

2.3. Textura

Esa variable hace referencia a la heterogeneidad espacial de una determinada cubierta, en definitiva al contraste espacial entre los elementos que la componen. Visualmente se manifiesta como la rugosidad o suavidad de los tonos de gris. Cuanto más similares sean, la tonalidad será más homogénea en el interior de la cubierta, y la textura será más lisa. Por el contrario, si existe una alta heterogeneidad en los niveles de gris de esa cubierta aparecerá como muy rugosa, con textura grosera.

La textura de una cubierta procede de la relación entre el tamaño de los objetos que la forman y la resolución del sensor. Cuando un objeto ocupa una superficie inferior a 1 mm^2 (en la resolución de la imagen) no puede identificarse individualmente, sino sólo a través de la variabilidad espacial que provoca. En función del tamaño de los objetos que forman una cubierta suelen distinguirse tres tipos de textura:

1. Textura grosera, cuando los objetos están comprendidos entre 0,25 y 1 mm^2 a la escala de la imagen.
2. Textura media, objetos comprendidos entre 0,04 y 0,25 mm^2.
3. Textura fina, objetos inferiores a 0,04 mm^2.

En sentido estricto, además del tamaño de los objetos que forman una determinada cubierta, la textura con la que aparece en la imagen puede variar en función de diversos factores. Los más importantes son el ángulo de observación del sensor (una observación más aguda incrementa la rugosidad), las condiciones de iluminación (a ángulos solares más bajos el efecto de sombras es más evidente), y la longitud de onda (una superficie lisa a longitudes largas puede aparecer como rugosa en cortas). Trabajando en el espectro visible e IRC, la rugosidad se modifica principalmente en función de las condiciones de iluminación solar. Un bosque natural, por ejemplo, puede ofrecer una textura muy variada a lo largo del año, dependiendo de la altura del sol sobre el horizonte y de su desarrollo estacional.

En cualquier caso, el criterio de textura es muy importante para discriminar determinadas cubiertas que pueden ofrecer un comportamiento espectral uniforme. Por ejemplo, los frutales en regadío y las caducifolias ofrecen una reflectividad muy similar, por cuanto, en muchas ocasiones, presentan grandes afinidades fisiológicas. De esta forma, el criterio de textura puede ser el único viable para distinguirlas. Los frutales ofrecen un marco de plantación regular —lo que implica menor variedad espacial en la cubierta—, mientras los árboles de hoja caduca aparecen con un desarrollo mucho más heterogéneo. En consecuencia, los frutales presentan una textura más fina, facilitando al intérprete la separación frente a especies forestales naturales (Gordon y Philipson, 1986).

La figura 5.7 recoge un ejemplo de la aplicación del criterio de textura. Incluye un fragmento de la imagen (Alcala87), adquirida por la cámara rusa KVR-1000, correspondiente a los márgenes del río Henares. Tanto los cultivos de regadío (A) como los árboles de ribera (B) ofrecen los mismos tonos, lo que permite diferenciarlos claramente de los suelos agrícolas ya cosechados (C), que ofrecen una tonalidad mucho más clara. Sin embargo, para distinguir entre A y B resulta preciso acudir a otros criterios, y en concreto a la textura espacial, ya que los cultivos son mucho más homogéneos espacialmente, ofreciendo por tanto una textura más lisa.

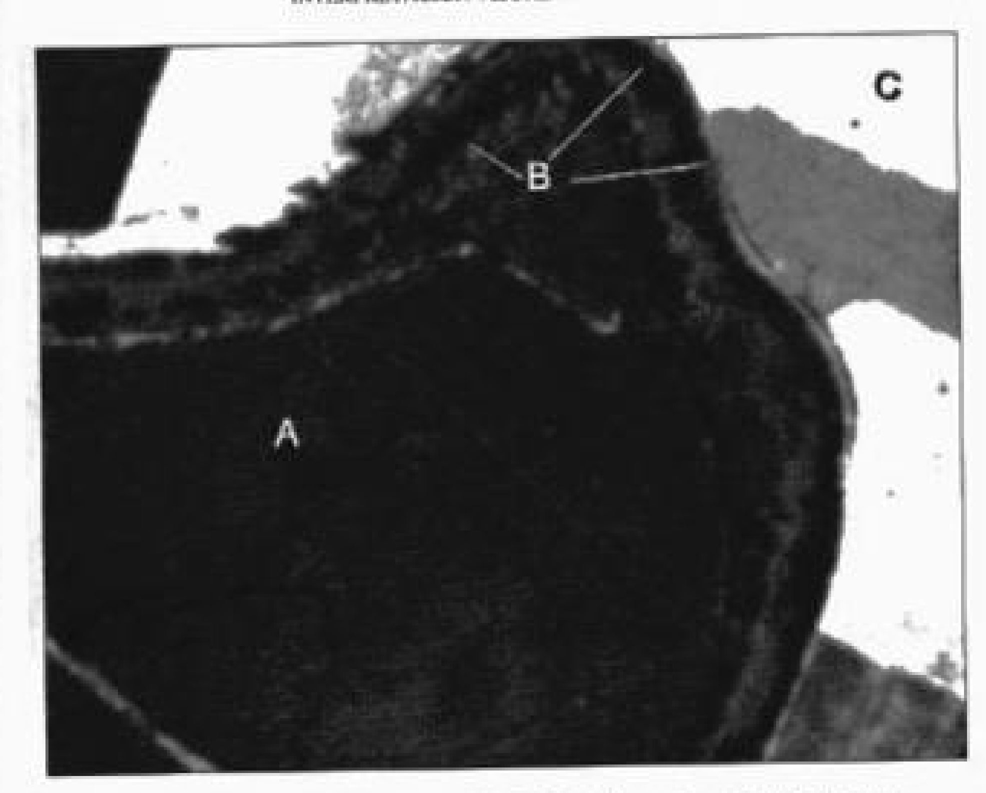


Fig. 5.7. *Fragmento de la imagen Alcalá87 sobre los márgenes del río Henares.*

Con imágenes de menor resolución, como la pancromática ETM+ que aparece en la figura 5.8, la textura puede facilitarnos la discriminación de las áreas urbanas (A, B) frente a los espacios agrícolas (C), que siempre tendrán una textura más lisa. Entre los sectores urbanos, la textura puede permitir diferenciar los barrios donde son dominantes las viviendas unifamiliares y el parcelario minucioso (A), típico de las áreas de nueva residencia y los cascos históricos, frente a los polígonos de bloques más grandes de viviendas (B), normalmente asociados a barrios periféricos.

2.4. Contexto espacial

Por situación o contexto espacial se quiere indicar la localización de las cubiertas de interés en relación con elementos vecinos de la imagen.

Un buen ejemplo del empleo de este criterio de interpretación hace referencia, de nuevo, al mundo urbano. Un jardín situado en el interior de la ciudad y formado por es-

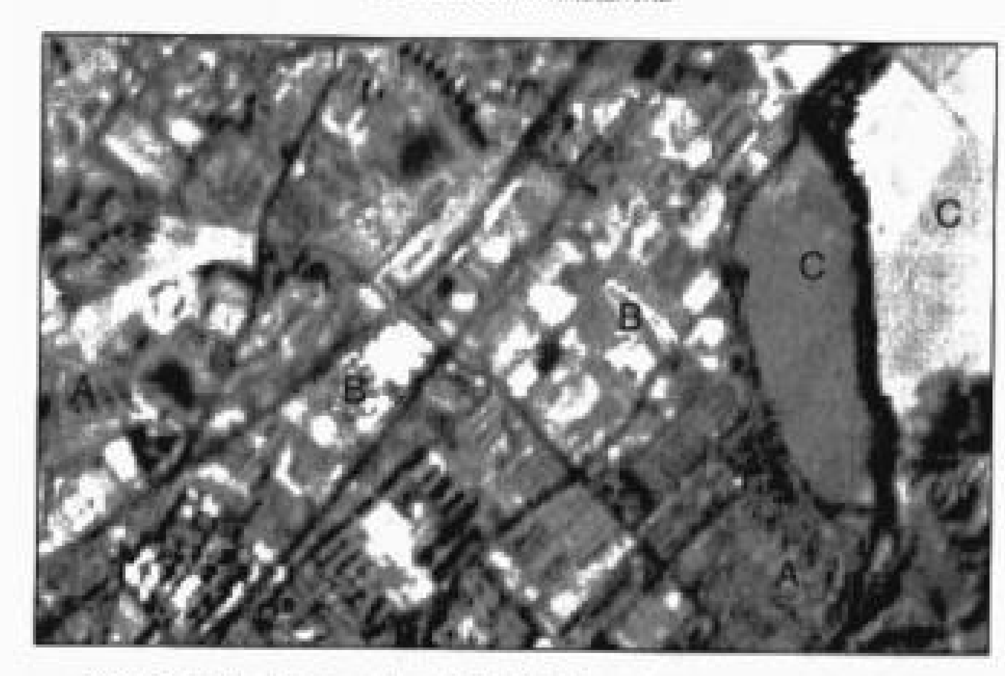


FIG. 5.8. *Sector del centro urbano de Alcalá sobre una imagen pancromática ETM+.* (Alcalá99.)

pecies de hoja caduca tiende a presentar un tono, un color y una textura muy similares a los que puede ofrecer un bosque natural de caducifolios. La confusión se debe a que ambas cubiertas están formadas por las mismas o similares especies, incluso con densidades y heterogeneidad (textura) muy parejas. En esa situación, no cabe más criterio para separarlas que ponerlas en relación con el entorno geográfico: aquellas que aparezcan en el interior de una superficie edificada, más o menos densa, pueden considerarse como parques urbanos, mientras las que se sitúen en un contexto de vegetación natural serán asignadas a la categoría bosques. En similares términos cabe expresarse en lo que se refiere a la separación entre árboles de ribera y otras especies caducifolias, ya que las primeras —como su nombre indica— se asocian con cursos fluviales.

En la figura 5.9 aparece un ejemplo en donde resulta especialmente evidente el criterio del contexto espacial. Se trata de dos sectores correspondientes a cubiertas herbáceas sometidas a riego, por lo que ofrecen tonos claros en el infrarrojo cercano. Aunque las especies son similares y el tratamiento que se aplica también (ambas son regadas), su sentido temático es muy distinto, ya que una imagen alberga unos campos de golf en el noroeste de la ciudad de Madrid, y otra unos cultivos forrajeros próximos al río Jarama. Ambas cuentan con similares características espectrales, pero su emplazamiento (además de la forma y patrón espacial) permite discriminarlas con fidelidad.

Estas distinciones, tan importantes desde el punto de vista de la cartografía temática, son más fácilmente abordables mediante interpretación visual, puesto que la clasificación digital no considera en sí el contexto geográfico, al ser muy complejo de definir en términos numéricos. No obstante, en posteriores capítulos veremos algunas posibilidades en este sentido (cap. 7.4).

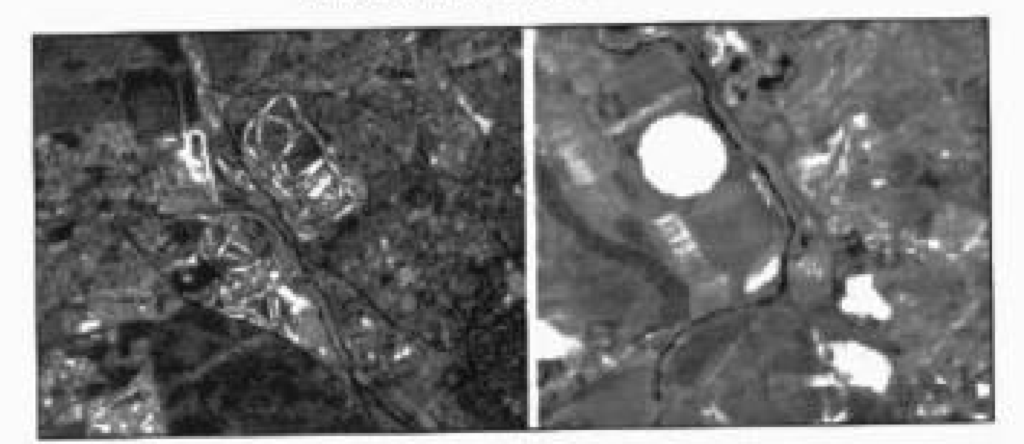


FIG. 5.9. *El criterio de contexto espacial permite distinguir entre campos de golf (izquierda) y cultivos bajo riego (derecha), al estar los primeros próximos a una zona urbana y los segundos a un sector agrícola.*

2.5. Sombras

La variación de las condiciones de iluminación en una cubierta introduce una notable variedad en su firma espectral característica, de tal forma que una misma cubierta puede ofrece valores de reflectividad bastante contrastados según se sitúe en una vertiente iluminada directamente por el sol, o en umbría. Este aspecto conviene tenerlo en cuenta, de cara a evitar señalar fronteras entre coberturas allí donde sólo hay cambios en las condiciones de iluminación. Ya veremos, más adelante, algunos criterios para corregir este efecto de cara a la clasificación de las imágenes (cap. 6, apdo. 6.2.3).

Ahora bien, en el campo del análisis visual, la sombra producida por la iluminación que recibe un determinado objeto resulta, en muchas ocasiones, un criterio clave para detectarlo o identificarlo, ya que nos proporciona una idea de su altura y profundidad. Además, permite realzar la interpretación de los rasgos geomorfológicos y de la textura de la imagen, especialmente en zonas forestales. Asimismo, nos permite calcular la altura de edificios, siempre que conozcamos los ángulos solares en el momento de adquirir la imagen. Basta para ello aplicar una sencilla relación trigonométrica (fig. 5.10):

$$h = \frac{ls}{\tan \theta} \qquad [5.1]$$

donde h es la altura del edificio, ls la longitud de la sombra y θ el ángulo cenital solar (alternativamente, puede multiplicarse ls por la tangente del ángulo de elevación). El método será más apropiado para edificios exentos, ya que en zonas urbanas densas puede resultar complicado delimitar la sombra de un edificio singular de la procedente de otros inmuebles.

La figura 5.11 recoge un ejemplo de la aplicación de este criterio, para algunos

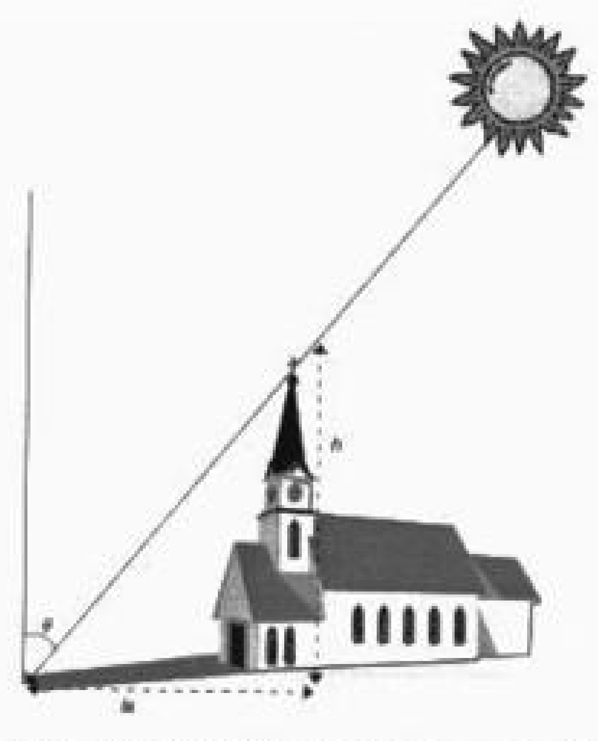


FIG. 5.10. *Esquema para el cálculo de altura de edificios a partir de las sombras.*



FIG. 5.11. *Ejemplo de estimación de alturas en la ciudad de Alcalá. Las letras denotan distintas tipologías de edificios.* (Imagen Alcalá87.)

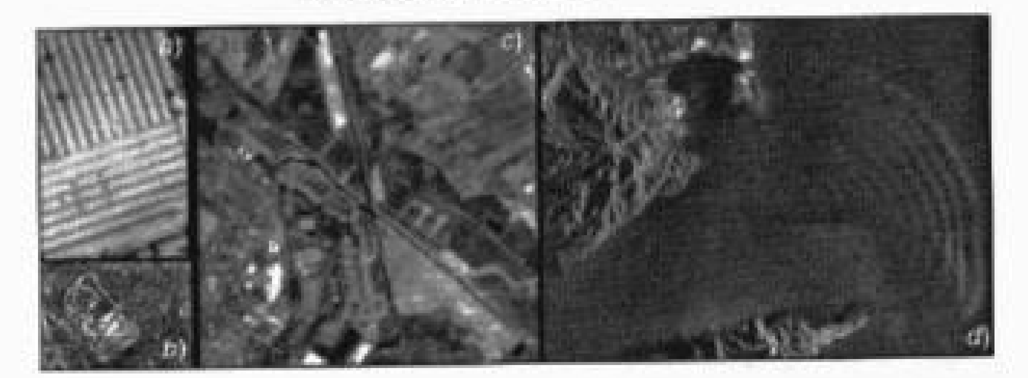


FIG. 5.12. *Ejemplo de identificación de cubiertas a partir del patrón espacial:* a) *fábricas en imágenes KVR-1000;* b) *campo de golf, y* c) *aeropuerto (ambas en imágenes TM);* d) *estructuras oceánicas.* (Imagen ERS.)

barrios periféricos de Alcalá de Henares. La imagen corresponde a la misma adquisición de la cámara KVR-1000 antes comentada. Su magnífica resolución permite calcular con bastante nitidez la longitud de las sombras, estimándose las alturas para las distintas tipologías de edificios en A ≈ 35 m; B ≈ 25 m; C ≈ 6 m, y D ≈ 8 m.

2.6. Patrón espacial

Este concepto indica una organización peculiar de los objetos que forman una determinada cubierta. Este criterio se emplea mucho en fotografía aérea (por ejemplo, para distinguir un olivar —en plantación regular— de una dehesa). En imágenes de satélite ha estado bastante limitado como consecuencia de la baja resolución de la mayor parte de los sensores disponibles hasta hace unos años. Con el mayor empleo de los equipos de alta resolución ganará un mayor protagonismo en el futuro. No obstante, aún sobre imágenes Landsat-ETM+, por ejemplo, puede permitirnos identificar algunas cubiertas artificiales, como serían las plantaciones forestales (que pueden presentar en la imagen una alternancia de caminos/vegetación bastante particular), o los campos de golf, que ofrecen en el infrarrojo cercano una peculiar alternancia de sectores de alta reflectividad (las calles y *greens*) y media (la vegetación original del entorno: fig. 5.12). Similar criterio puede emplearse para identificar tipos de cobertura del suelo, estructuras geológicas o marinas.

2.7. Forma - Tamaño

La forma de un determinado objeto es una clave determinante para identificarlo, ya que su contorno nos permite asimilarlo a alguno de los patrones que nos resultan familiares. Al igual que en otros criterios visuales, la forma resulta más determinante en imágenes de alta resolución espacial, ya que permite reconocer el perfil específico de muchos más objetos, limitándose sólo a los de gran tamaño en las imágenes de resolución media. A partir de la forma, por ejemplo, podemos determinar la presencia de

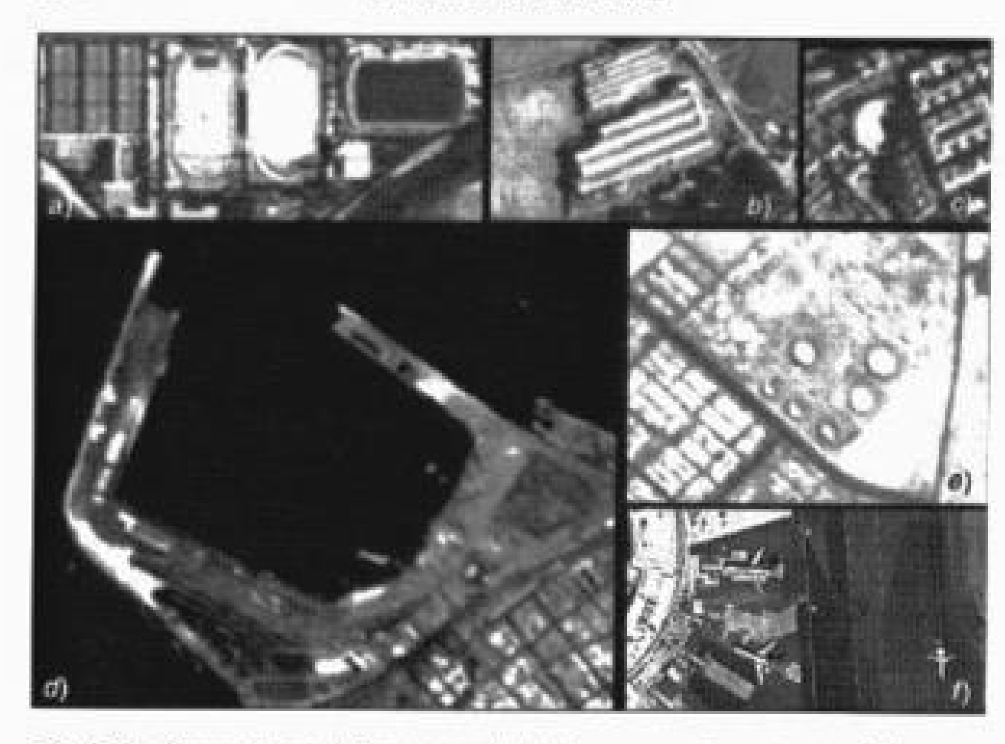


FIG. 5.13. *Reconocimiento de formas a partir de imágenes espaciales: a) campos de deporte; b) fábricas; c) plaza de Toros; d) puerto; e) tanques de combustible; f) aviones.*

ciertos elementos urbanos: instalaciones deportivas, centros comerciales, aeropuertos o fábricas (fig. 5.13). También facilita la discriminación entre carreteras y línea de ferrocarril (de trazado menos sinuoso), o de los ríos frente a los canales artificiales, que ofrecerán un aspecto más geométrico. También permite reconocer estructuras geológicas bien definidas: volcanes, domos o lineamientos, así como algunas perturbaciones meteorológicas (ciclones tropicales, por ejemplo: fig. 5.14).

En caso de posible duda a partir de la forma, el tamaño complementa bastante la identificación de una cubierta. Por ejemplo, la forma de un campo de tenis y de fútbol es similar, pero no [illegible]amaño. El empleo de este criterio viene marcado por la resolución espacial de las imágenes. En aquellas de mayor resolución pueden identificarse objetos particulares (edificios singulares), mientras en las de menor detalle sólo pueden señalarse rangos de tamaño para ciertos tipos de superficie (embalses, áreas inundadas). A consecuencia de esa peor resolución, en ocasiones no podremos identificar la forma de un objeto determinado, pero sí de una agrupación de objetos, sirviendo a la postre para identificar un tipo de cubierta. Por ejemplo, un pinar de repoblación aparecerá con un perímetro más geométrico que un pinar natural (o fruto de una repoblación ya muy consolidada y transformada).

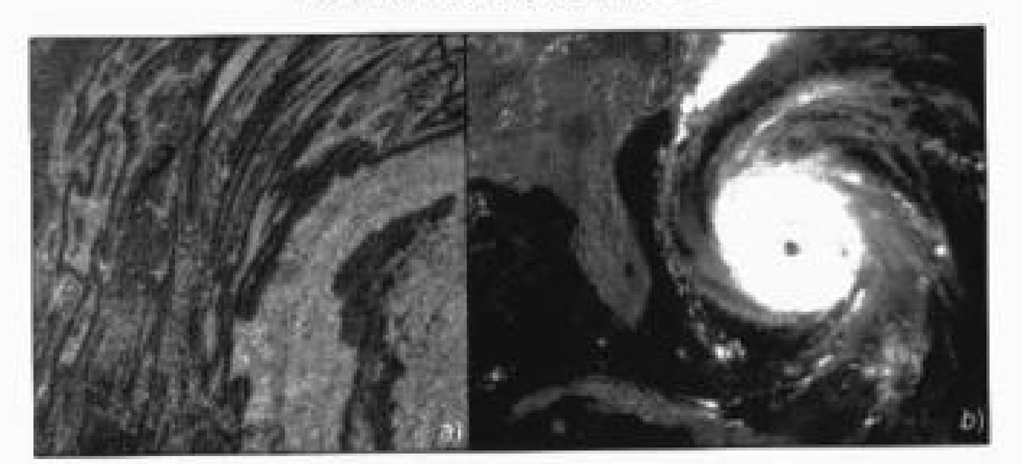


FIG. 5.14. *Empleo de la variable forma sobre grandes tamaños: a) relieve apalachiense sobre una imagen MSS; b) ciclón tropical en una imagen AVHRR.*

2.8. Visión estereoscópica

Resulta fundamental para el reconocimiento geomorfológico y de cubiertas del suelo, pues aporta una visión tridimensional del espacio observado. Como ya hemos señalado, la mayor parte de los sensores espaciales todavía no poseen esta capacidad. Excepción a esta norma son las imágenes adquiridas por sensores fotográficos y por el satélite SPOT, como ya vimos en el capítulo 3. En el resto, sólo puede obtenerse visión estereoscópica en las zonas de solape entre órbitas, restringiendo este criterio a una estrecha banda lateral del conjunto de la escena. Probablemente, la lista se amplíe en un futuro inmediato si pasa a un plano central la elaboración de cartografía básica a partir de sensores espaciales, si bien ya existen técnicas alternativas a la estereoscopía para generar información sobre alturas (lídar de distancias, interferometría radar).

2.9. Periodo de adquisición

La mayor parte de los especialistas están de acuerdo en que la observación sistemática de la superficie terrestre es una de las principales ventajas de la teledetección desde el espacio. Las características orbitales de un satélite permiten que las imágenes sean adquiridas periódicamente y en condiciones similares de observación, facilitándose así cualquier estudio que requiera una dimensión temporal.

Hasta el momento presente, este análisis multi-temporal se ha abordado con una doble orientación (fig. 5.15):[2]

2. Más tarde tendremos ocasión de profundizar en estos enfoques, dentro del capítulo dedicado a técnicas de detección de cambios (cap. 7, apdo. 3).

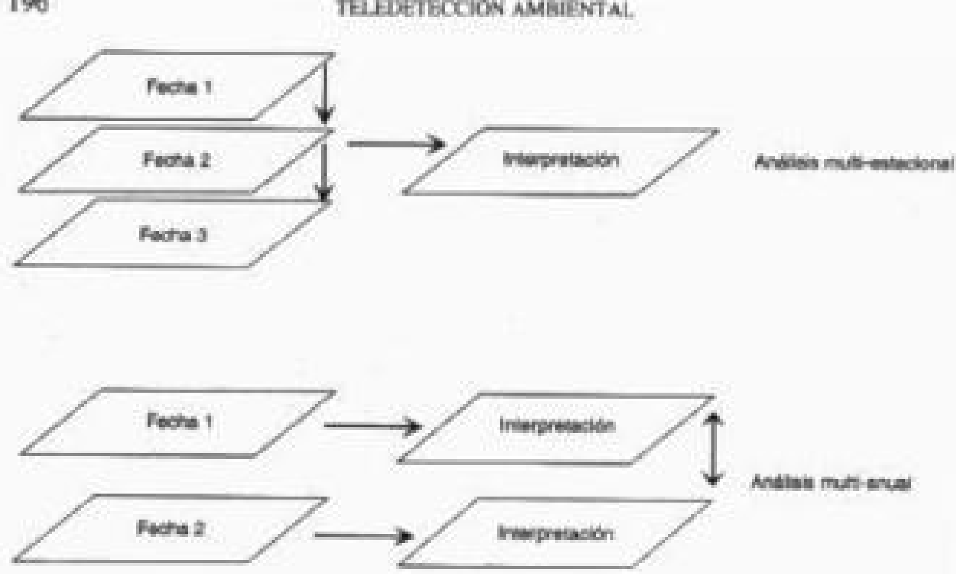


FIG. 5.15. *Dimensiones temporales en la interpretación de imágenes.*

1. Por un lado, con objeto de detectar cambios entre dos fechas de referencia, deduciendo de ahí la dinámica del medio natural o las repercusiones de la acción humana sobre ese medio, y planeando, en consecuencia, las medidas adecuadas para evitar su deterioro o asegurar su mejor conservación. Este enfoque podría denominarse multi-anual, por cuanto se utiliza el factor tiempo para seguir la evolución de una zona en un período relativamente dilatado.
2. Por otro lado, podríamos hablar de un enfoque multi-estacional, en donde la dimensión tiempo se utilizaría para perfeccionar la interpretación de la imagen, gracias a incorporar información sobre el ciclo estacional de las cubiertas vegetales. Este enfoque resulta de gran utilidad para discriminar tipos de cultivos y especies forestales. Previamente, el intérprete debe conocer bien el calendario estacional de estas especies, con objeto de seleccionar los períodos más apropiados para discriminarlas, frente a otras que pueden presentar un comportamiento espectral similar en algunos momentos del año. Algo similar ocurre cuando sólo estamos trabajando con una imagen: la fecha elegida debe ser la más idónea para conseguir separar la cubierta de interés. Por ejemplo, una cartografía de regadíos requiere trabajar con imágenes de la estación seca, mientras un estudio geomorfológico tenderá a enfatizar las imágenes de invierno, en donde son más evidentes los lineamientos estructurales por el efecto de sombras.

Independientemente del tipo de enfoque que pretenda seguirse, cualquier estudio multi-temporal implica una labor previa de corrección, con objeto de combinar adecuadamente las dos o más imágenes que van a intervenir en el análisis. Conviene tener en cuenta que los brillos-color-textura están en relación con las condiciones medioambientales y de adquisición, por lo que no han de considerarse en sentido absoluto; esto es, resulta recomendable aplicar esos criterios a la discriminación de cubiertas en cada imagen y no al conjunto de las diferentes fechas que intervengan en el proyecto.

Con estas salvedades, el factor multi-temporal representa un criterio de identifi-

cación muy importante en análisis visual, tanto en enfoques multi-anuales (Crapper y Hynson, 1983; Eyton, 1983; Renz, 1985), como multi-estacionales (Bronsveid y Luderus, 1982; Chuvieco, 1986; Chuvieco y Martínez Vega, 1990; Hilwig, 1980).

Algunos estudios multi-temporales se han basado en técnicas de composición de color para realzar cambios entre dos fechas de referencia. Éste es el caso de un trabajo dirigido a detectar espacios forestales sometidos a plagas de defoliación en Canadá, en donde se aplicó cada uno de los tres colores elementales a las bandas IRC y R de las dos fechas de referencia (Hall *et al.*, 1984).

3. **Elementos de análisis visual**

Tras el repaso de los criterios sobre los que se basa la interpretación visual de imágenes nos centramos en una serie de elementos a considerar para cualquier trabajo práctico a partir de este tipo de información.

3.1. CARACTERÍSTICAS GEOMÉTRICAS DE UNA IMAGEN ESPACIAL

Aunque una imagen adquirida desde el espacio presenta menos errores geométricos que una fotografía aérea, como consecuencia de la mayor estabilidad y altura de vuelo de la plataforma, esto no quiere decir que esté libre de distorsiones, por lo que no puede superponerse directamente sobre la cartografía básica. Más adelante trataremos de los procesos que se aplican a la corrección de estos errores geométricos. Basta aquí apuntar que ese desajuste está originado por tres factores: 1) por errores, propiamente dichos, en la adquisición de la imagen; 2) por la diferencia entre las proyecciones de la imagen y el mapa (la primera cónica, y la segunda normalmente cilíndrica), y 3) por la propia deformación que cualquier mapa implica de la superficie terrestre.

Una vez resueltos estos problemas, la imagen de satélite puede servir para actualizar aspectos planimétricos de la cartografía, sobre todo a escalas pequeñas y medias, dependiendo de la resolución espacial del sensor que se utilice. Existen abundantes experiencias en este sentido (Martínez Vega, 1996), no sólo en áreas de difícil acceso con métodos convencionales (Arbiol *et al.*, 1994), sino también en países con buena cobertura cartográfica (Arozarena *et al.*, 1989).

3.2. EFECTO DE LA RESOLUCIÓN ESPACIAL EN EL ANÁLISIS VISUAL

Antes se indicó que la resolución espacial hace referencia al tamaño de la mínima unidad discriminable sobre la imagen. Este concepto, en análisis visual, se relaciona tanto con el tamaño del píxel, como con la escala a la cual se representa la imagen.

La resolución espacial tiene una repercusión importante sobre la interpretabilidad de la escena. De entrada, como hemos visto, aquellos elementos por debajo del tamaño del píxel no serán identificables en la imagen, lo que supone un elemento fundamental en la selección del sensor más conveniente para cada objetivo. Además, cuanto mayor sea la resolución, mejor podrá definirse un píxel, ya que será más susceptible de

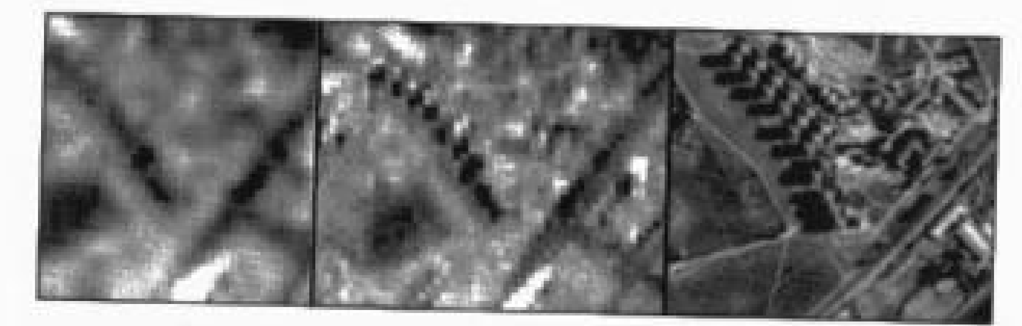


FIG. 5.16. *Efectos de la resolución espacial sobre la interpretación de imágenes: el mismo sector de la ciudad de Alcalá se recoge por una imagen Landsat-ETM+ (Banda 3:30 m), su canal pancromático (15 m) y una imagen KVR-1000 (2 m).*

albergar una sola cubierta. Por el contrario, si el tamaño del pixel es grande, la señal detectada resulta frecuentemente de varios tipos de cubierta, haciendo mucho más compleja su interpretación.

El efecto de la resolución espacial sobre la calidad final de la imagen se pone de manifiesto en el análisis de la figura 5.16. Incluye tres imágenes adquiridas por los sensores ETM+ (multiespectral y pancromático) y la cámara KVR-1000 sobre un pequeño sector de la ciudad de Alcalá. Resulta evidente el deterioro de la identificación de los edificios y sus sombras en las imágenes de menor resolución.

La figura 5.17 incluye dos imágenes TM y MSS sobre el entorno urbano de Madrid. En ellas puede comprobarse el efecto de la resolución espacial sobre la interpretación de imágenes, en este caso a escala más regional. Se sugiere realizar unos transparentes sobre la red hidrográfica, autovías nacionales, estructura urbana, aeropuertos (Barajas, Cuatro Vientos), y grandes objetos de referencia: parques y jardines, Mercamadrid, hipódromo, Palacio Real, etc. Todos estos elementos son claramente identificables sobre la imagen TM y muy complejos sobre la obtenida por el MSS, pues todos ellos están influidos por la diferente resolución espacial que brindan estos sensores (30 y 80 m, respectivamente).

3.3. Efecto de la resolución espectral en el análisis visual

El carácter multi-espectral de las imágenes espaciales resulta básico para su interpretación. La posibilidad de observar un fenómeno en diversas bandas del espectro amplía notablemente nuestra capacidad de reconocerlo. Como vimos en el capítulo 2, cada cubierta ofrece un comportamiento espectral tipo, en función de las características de sus componentes, que denominamos firma espectral. Allí se indicaba que ese comportamiento tipo se modifica por una serie de factores externos al sistema cubierta-sensor, estableciéndose una cierta variabilidad espectral en torno a ese comportamiento genérico.

En cualquier caso, el conocimiento de esos rasgos espectrales resulta muy interesante para proceder a una interpretación más razonada de la imagen. Un intérprete

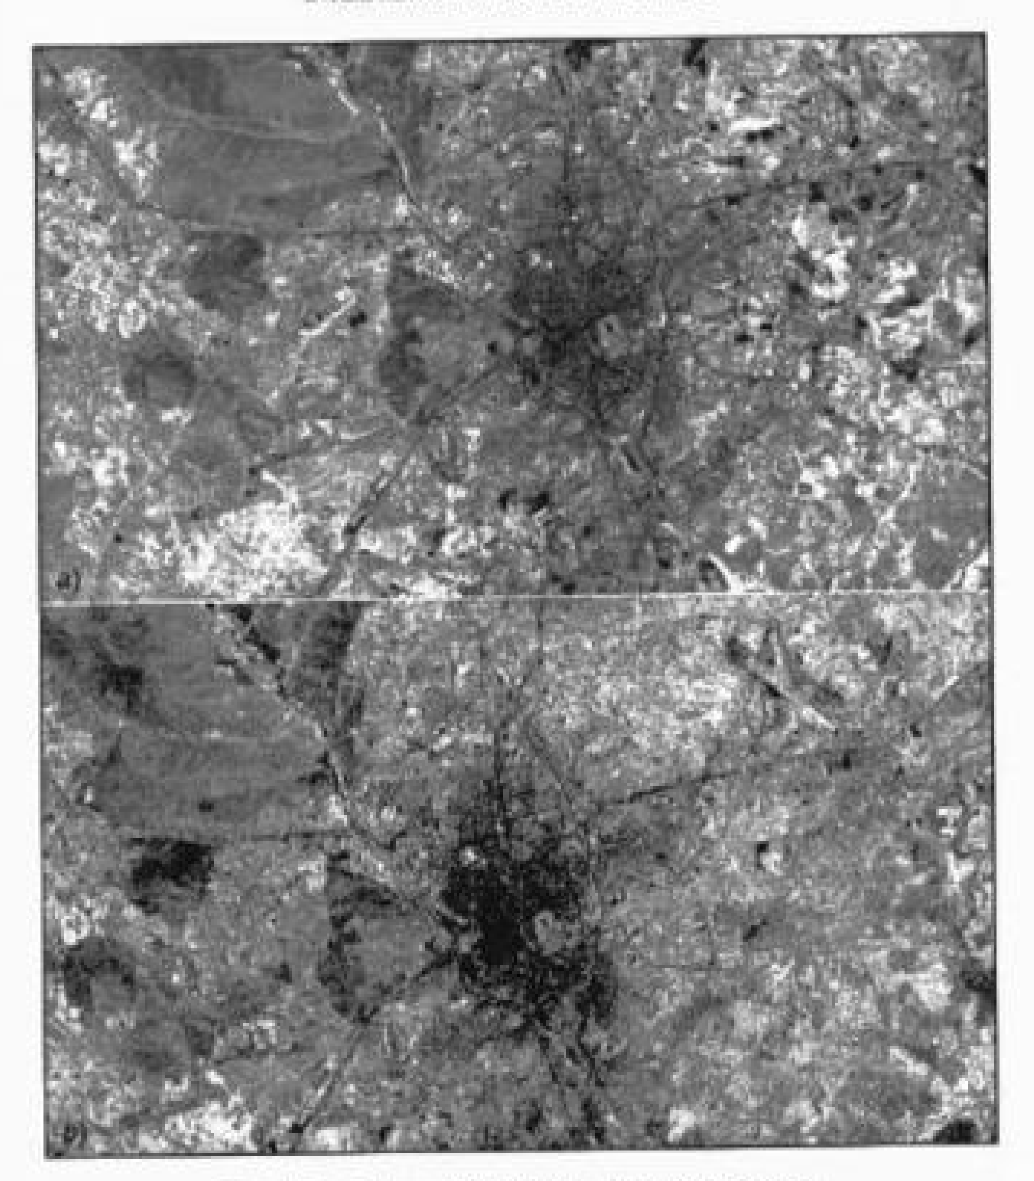


FIG. 5.17. *Imágenes TM y MSS sobre la ciudad de Madrid.*

puede acostumbrarse a observar las masas vegetales con tonos oscuros en las bandas visibles y claros en el IRC, sin considerar los factores que inciden en ese fenómeno. No cabe duda que si éstos se tienen presentes en la interpretación de la imagen, resulta más fácil adaptarlos a zonas o categorías peor conocidas, convirtiendo la teledetección en una técnica aplicable a contextos más amplios.

No quiere esto decir que los tonos de gris de las distintas bandas sean una traducción estricta de las curvas de reflectividad previamente analizadas. Son, más bien, una representación visual de los valores numéricos almacenados por el sensor —conse-

A. Zonas urbanas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

B. Áreas residenciales exentas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

C. Láminas de agua

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

D. Cultivos de secano

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

E. Coníferas

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

F. Frondosas caducifolias

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

G. Frondosas perennifolias

Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

H. Pastizales

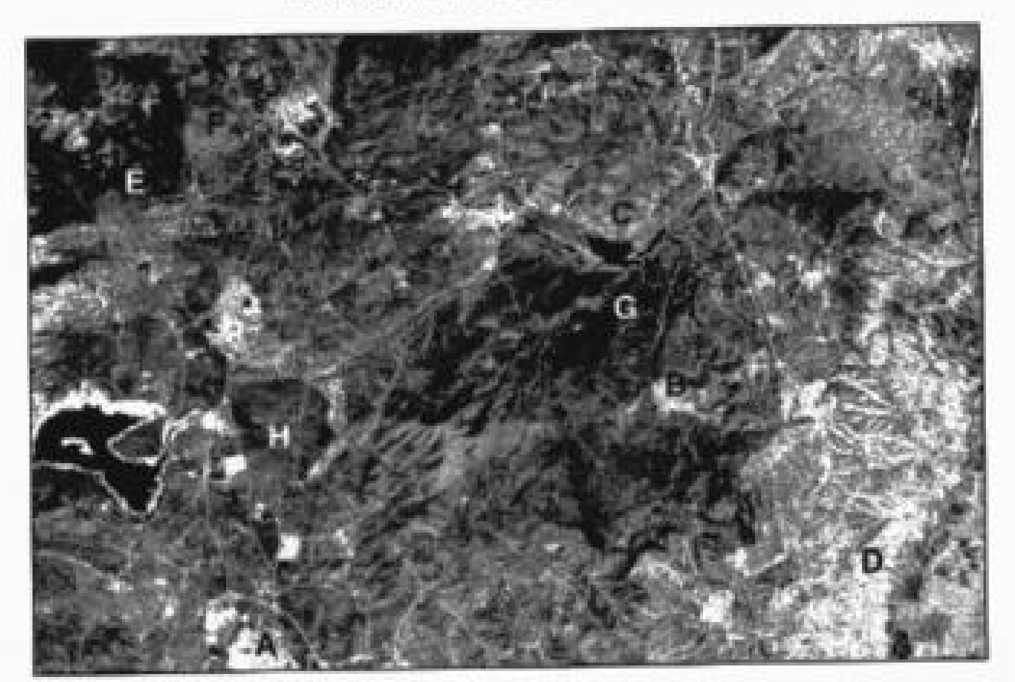
Tono	B1	B2	B3	B4	B5	B7
Muy claro						
Claro						
Oscuro						
Muy oscuro						

FIG. 5.18. *Gráfico para la construcción de curvas espectrales cualitativas.*

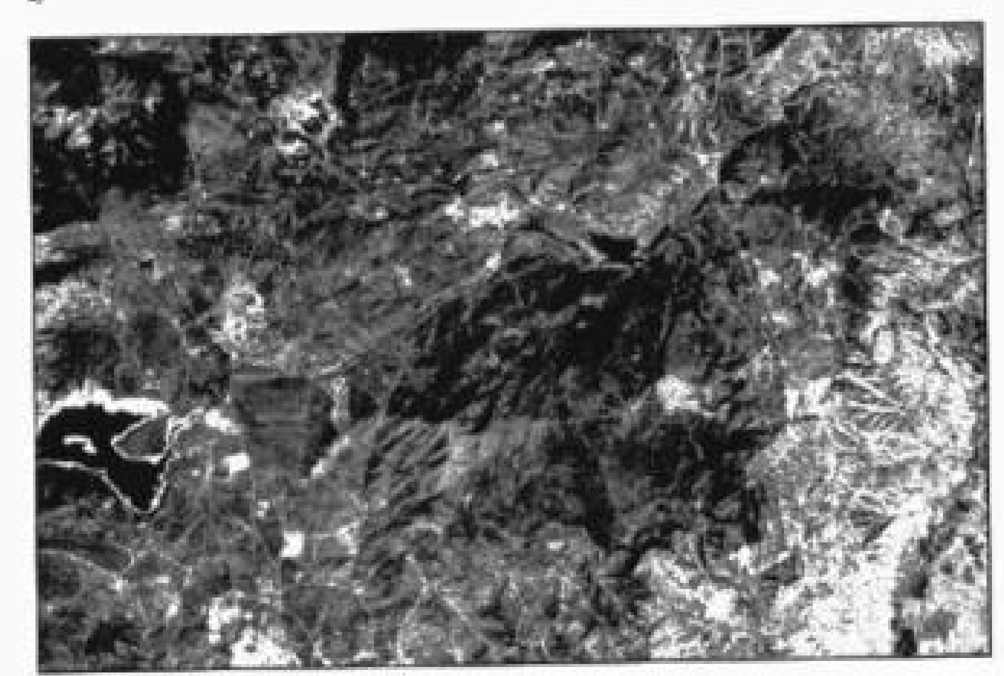
cuencia, a su vez, de esa reflectividad—, pero no identificables con ella, ya que cuentan también los valores de calibración de cada sensor y los efectos atmosféricos que han interferido la señal.

En cualquier caso, puede resultar interesante hacer un pequeño ejercicio de caracterización espectral de distintas cubiertas a partir del análisis visual. El ejercicio propuesto —que se adapta de uno similar ideado por Short (1982)—, pretende que el lector complete la información incluida en la figura 5.18, a partir de los tonos de gris que observe en las distintas bandas espectrales incluidas en la figura 5.19*a-b-c-d-e-f*. Se trata de las seis bandas ópticas del sensor ETM, correspondientes a una adquisición realizada por el satélite Landsat-7 en marzo de 2000. Recoge la zona abarcada por la hoja del mapa topográfico nacional denominada Torrelaguna. Por esta razón, la identificaremos como Torrel00, y será la base para buena parte de los ejemplos que se presenten en los dos siguientes capítulos referidos a la interpretación digital.

Con objeto de facilitar la búsqueda de espacios que definen cada uno de los tipos de cubierta puede consultarse la cartografía disponible sobre este sector, si bien se indican, en la primera banda, algunas zonas que pueden ayudar en dicha identificación. A partir de ahí, el intérprete puede analizar los rasgos espectrales de dichas cubiertas en el resto de las bandas consideradas.

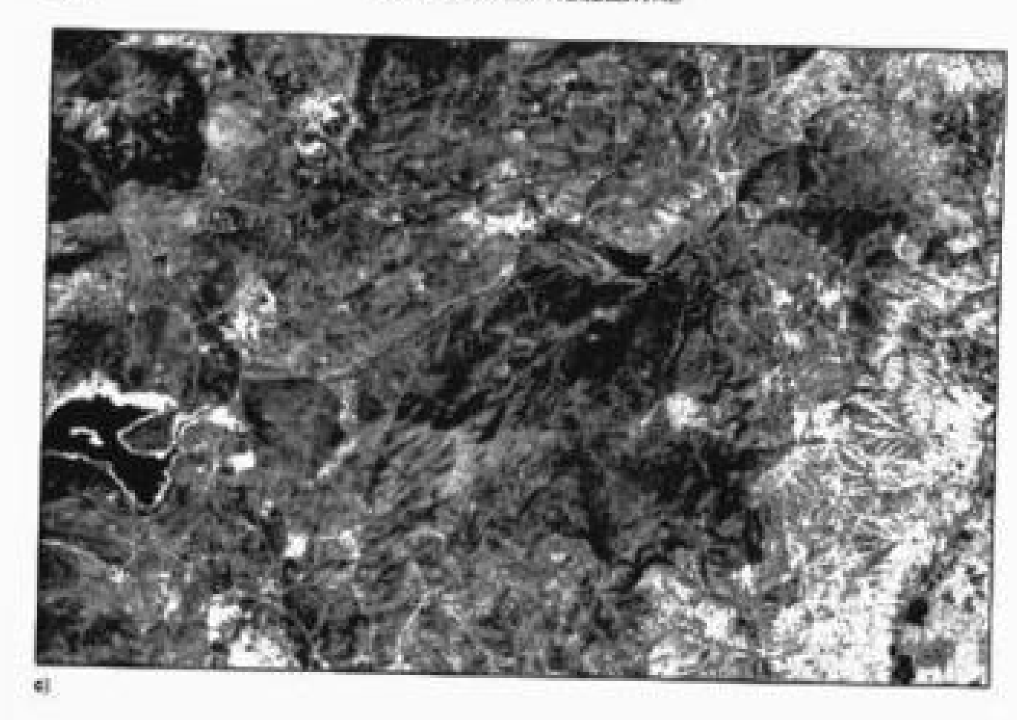


a)



b)

FIG. 5.19*a-b*. *Efecto de la resolución espectral en la interpretación de imágenes: a) Banda 1. b) Banda 2, c) Banda 3, d) Banda 4, e) Banda 5 y f) Banda 7 de la imagen Torrel00.*


c)


d)

FIG. 5.19c-d.


e)

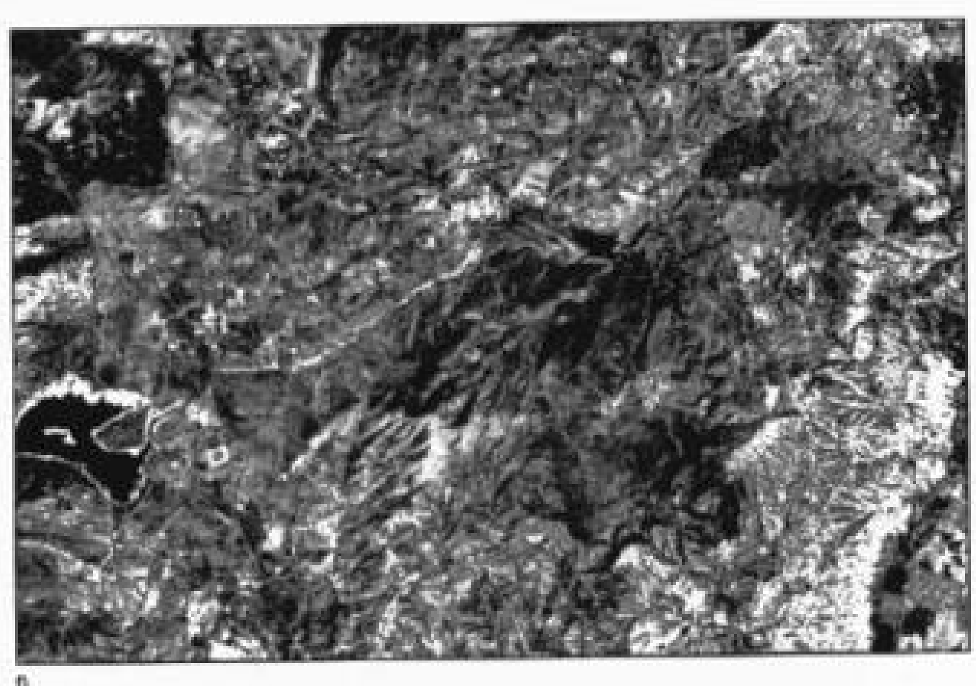

f)

FIG. 5.19e-f.

Una vez completado el gráfico será posible responder a las siguientes preguntas: ¿es posible distinguir entre perennifolias y caducifolias considerando la fecha del año en que está tomada la imagen?, ¿en qué bandas?, ¿qué base física tiene esa distinción?, ¿qué banda es más idónea para cartografiar los cultivos de secano frente al agua?, ¿por qué?, ¿se mantendría en otra fecha del año esa separación, por ejemplo en verano? ¿Qué banda indica mejor las redes de transporte?

3.4. Interpretación de composiciones en color

A partir de este ejercicio y de la teoría del color previamente comentada resultará más sencillo interpretar combinaciones multi-banda. Basta tener en cuenta que el proceso aditivo implica que los píxeles tendrán tanto mayor intensidad de un determinado color cuanto más blancos aparezcan en la banda a la que se aplique ese color. Si optamos, por ejemplo, por una composición en falso color (IRC, R, V), un píxel aparecerá rojo cuanto mayor intensidad presente en el IRC y menor en las dos restantes. Éste es el caso de las zonas cubiertas por vegetación vigorosa, que ofrecen un tono claro en el IRC, oscuro en el R y medio en el V, por lo que tienden a teñirse con un color rojo o rojo-magenta. Por el contrario, una lámina de agua, que aparece oscura en la banda espectral V y negra en las restantes, tenderá a mostrar un azul oscuro, ya que cuenta con un débil componente de azul y casi nulo de verde y rojo.

Siguiendo este razonamiento, el lector puede contestar a las siguientes preguntas: ¿en qué color aparecerán las coníferas?, ¿y las zonas urbanas?, ¿qué combinación de color se requiere para que la vegetación aparezca en verde? En esa nueva combinación, ¿cómo aparecerían las zonas urbanas, el agua y las coníferas?, ¿qué asignación de colores complementarios se requeriría para lograr las mismas tonalidades?

En el CD-ROM adjunto a esta obra se incluyen algunas composiciones en color para la imagen Torrel00, que servirán al lector para verificar las hipótesis que haya planteado en el párrafo anterior.

A partir de esas imágenes, o de las series cartográficas que distribuyen varias agencias cartográficas nacionales, pueden realizarse una serie de ejercicios de interpretación de la imagen. Por ejemplo, los siguientes:

1. Identificar tono y textura de las siguientes cubiertas: cultivos herbáceos de secano, cultivos leñosos de secano, cultivos de regadío (dependiendo de la fecha), perennifolias, caducifolias, áreas residenciales, zonas urbanas densas, agua.
2. Con ayuda de un transparente, recorrer cada una de las carreteras principales de la imagen. Anotar qué tipo de coberturas atraviesan desde un determinado núcleo urbano.
3. Delimitar los sectores urbanos de la imagen. Distinguir entre núcleos urbanos densos y áreas residenciales exentas. Ponerlas en relación con la vegetación próxima, tipos de relieve y accesibilidad. ¿Cuál de estos factores es dominante?
4. ¿Puede establecerse una gradación de tipos de vegetación en función de la altitud? ¿qué tipo de especies aparecen en: pie de monte, escalón inferior, escalón superior, cumbre. ¿Pueden detectarse estas gradaciones sobre la imagen?, ¿por qué?

3.5. Ejercicios de análisis multi-temporal

Ya hemos comentado que el factor temporal puede abordarse con un doble objetivo: por un lado, reconstruir la variación estacional de la zona; por otro, la detección de cambios.

El primer aspecto supone utilizar la dimensión temporal para mejorar la interpretación de la imagen, al aportar un valioso informe sobre el desarrollo fenológico de las especies vegetales. El interés de utilizar este criterio puede orientarse a distintas aplicaciones: seguimiento de las condiciones del cultivo o el estado de los embalses podrían ser dos claros ejemplos. Por ejemplo, la figura 5.20 recoge cuatro imágenes MSS

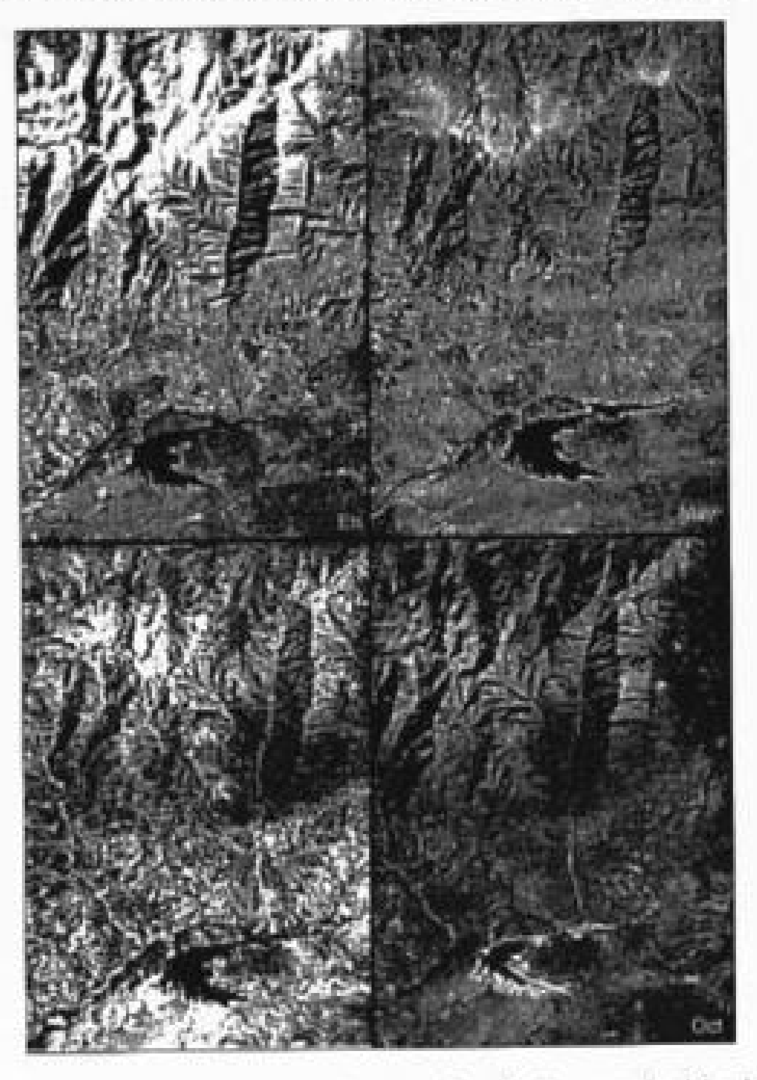


Fig. 5.20. *Imágenes de varias estaciones tomadas sobre las cercanías del embalse del Rosarito, en Cáceres: enero; mayo; julio y octubre de 1981.* (Banda IRC.)

tomadas en distintos meses del año, que permiten seguir la evolución estacional de la lámina de agua en el embalse de Rosarito. Al tratarse de una represa de régimen pluvio-nival, el mínimo anual se retrasa considerablemente respecto al centro del verano, observándose un nivel bastante alto en el mes de julio.

La figura 5.21 permite realizar una observación más amplia de esta variedad estacional, al incluir dos imágenes tomadas en primavera y en verano sobre el área de Torrelaguna. Permite determinar algunos rasgos de la evolución estacional de la vegetación natural, como el contraste entre perennifolios (A) y caducifolios (B), bien obvio en la imagen de verano, pero no tanto en la de primavera; la senescencia de los pastizales (C), con menor brillo en la imagen de verano a consecuencia de su marchitez; los cultivos de secano (D), que aparecen roturados en la imagen de verano, frente a los de regadío (E), que no se observan en la primera fecha. También aparecen dos nubes, con sus respectivas sombras, en la imagen de verano (F), y es evidente la reducción de la lámina de agua en algunos embalses (G).

El segundo enfoque del análisis multi-temporal se dirige a detectar cambios entre dos o más fechas alejadas en el tiempo, estudiando el dinamismo temporal de una determinada zona: crecimiento urbano, transformaciones agrícolas, obras de infraestructura, etc. También nos permite evaluar la superficie afectada por fenómenos efímeros, como es el caso de inundaciones o erupciones volcánicas, así como seguir la evolución de sus efectos.

Como muestra de las posibilidades de este enfoque del análisis multi-temporal se presenta la figura 5.22 (en color en fig. 22*), que incluye dos imágenes adquiridas por el sensor TM, con ocho años de diferencia (1984 y 1992), y otra más reciente, del ETM (año 2000). La resolución espacial y espectral de las imágenes es la misma, por lo que podemos emplear esta información para delimitar los principales cambios producidos en el área metropolitana de Madrid entre las tres fechas de referencia. Los cambios más evidentes son la construcción de la M-40 e inicio de la M-45, autovías de circunvalación exterior de la ciudad, la apertura del recinto ferial de Madrid, situado entre la M-40 y el aeropuerto de Barajas, la ampliación del mismo aeropuerto, con la tercera pista, y el inicio de múltiples promociones residenciales (ver elementos de situación en la fig. 5.23). En la imagen de 1992, la M-40 se observa con un brillo oscuro en el tramo comprendido entre la N-IV y la N-I, al este de Madrid, mientras aparece en tono claro hacia el oeste, ya que en esa fecha este tramo aún no se encontraba pavimentado. En 2000 ya aparece de color oscuro en todo su trazado, al estar completamente pavimentada; en cambio aparecen en tono claro la M-45 y un tramo del AVE Madrid-Barcelona, en obras.

Como grandes construcciones, destaca el recinto ferial de Madrid, donde se distinguen nítidamente los pabellones de exposición (por su gran tamaño y tono pueden discriminarse de las construcciones vecinas) y el estanque artificial del parque Juan Carlos I, así como los nuevos terminales del aeropuerto de Barajas (sólo en la imagen de 2000). También se delimitan perfectamente las nuevas áreas residenciales en torno a la M-40, con mayor intensidad en la última imagen, ya que se ha producido un notable desarrollo urbanístico de la ciudad en la última década.

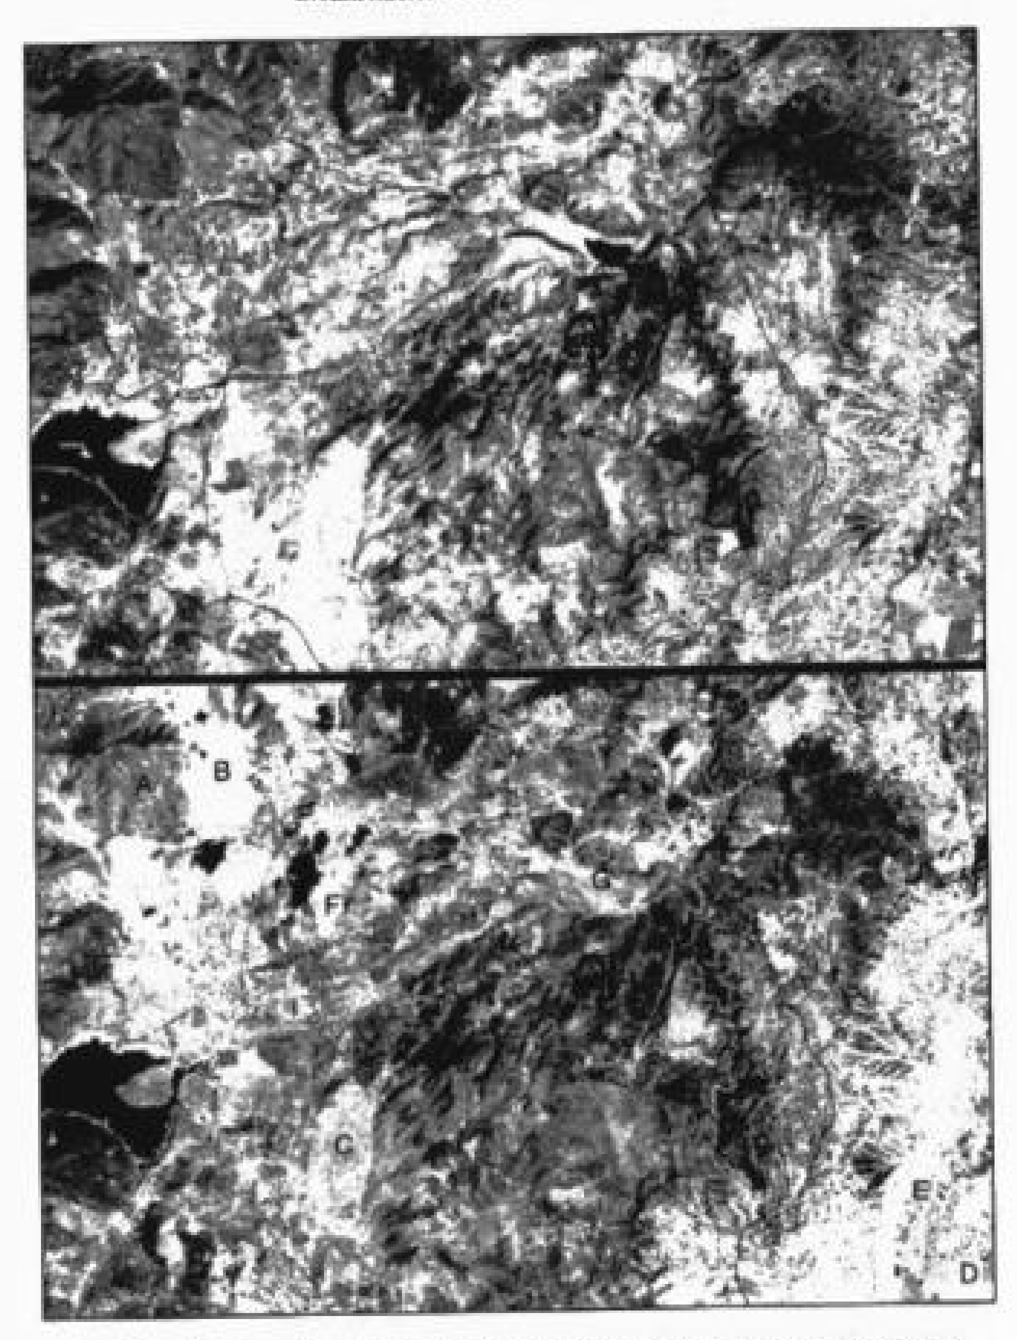


FIG. 5.21. *Imágenes de primavera (superior) y verano (inferior) del área de Torrelaguna.* (Banda IRC.)

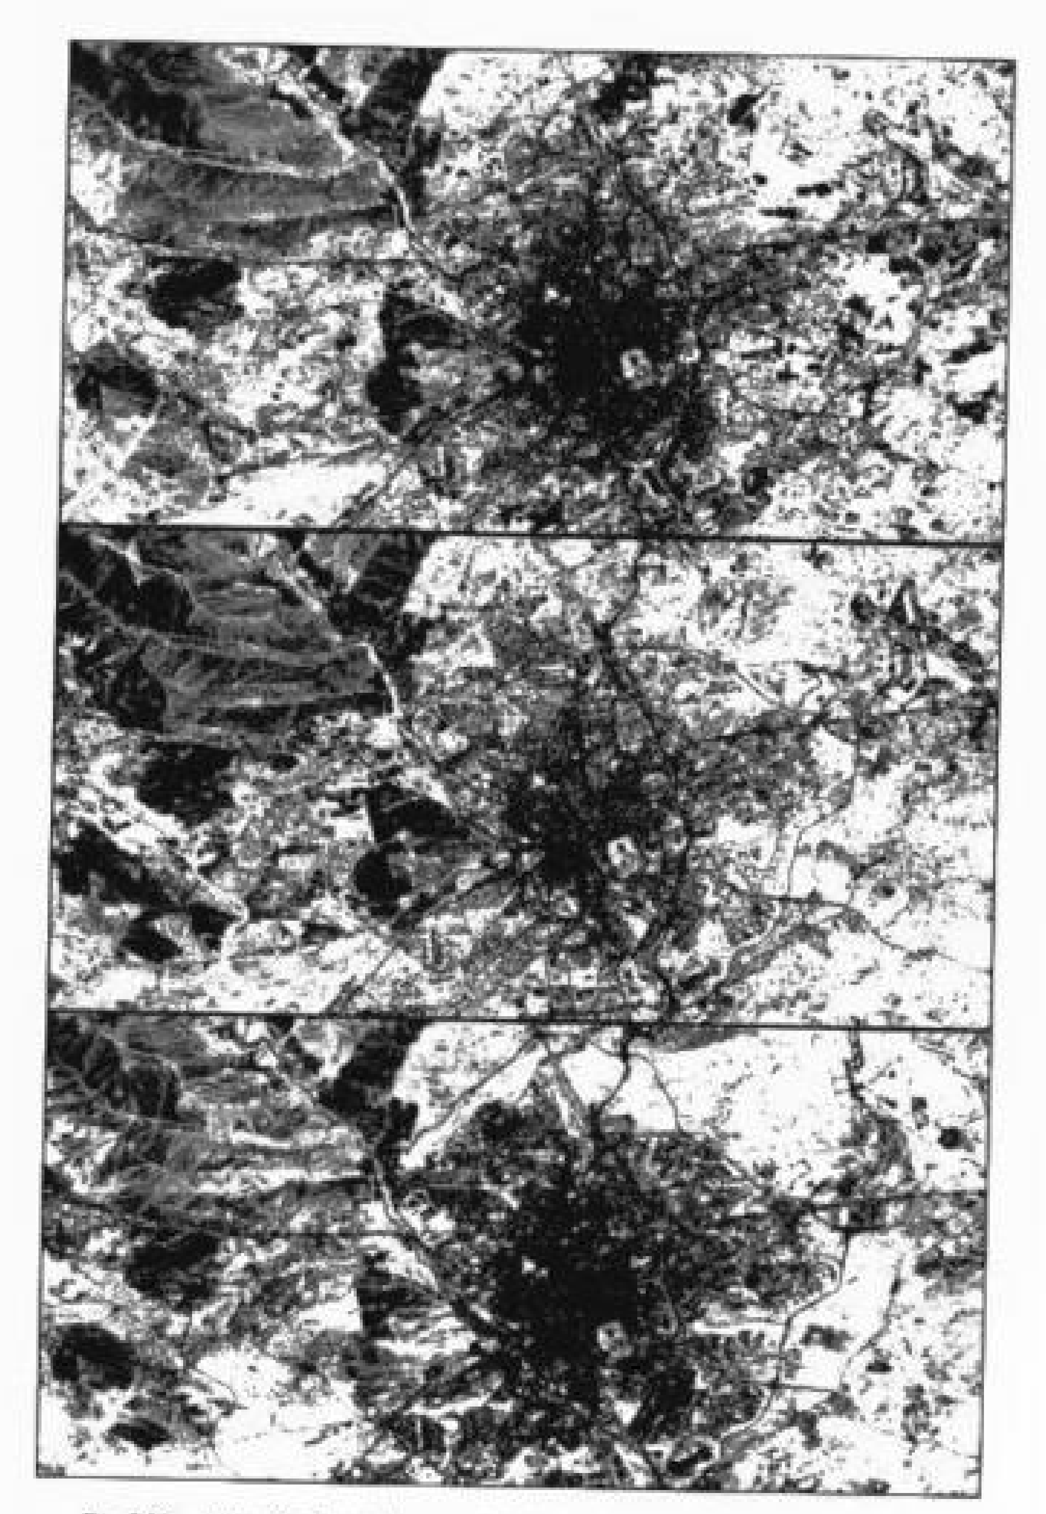


FIG. 5.22. *Detección de cambios por análisis visual: imágenes TM y ETM adquiridas en 1984, 1992 y 2000 sobre la ciudad de Madrid.* (Banda IRC.)

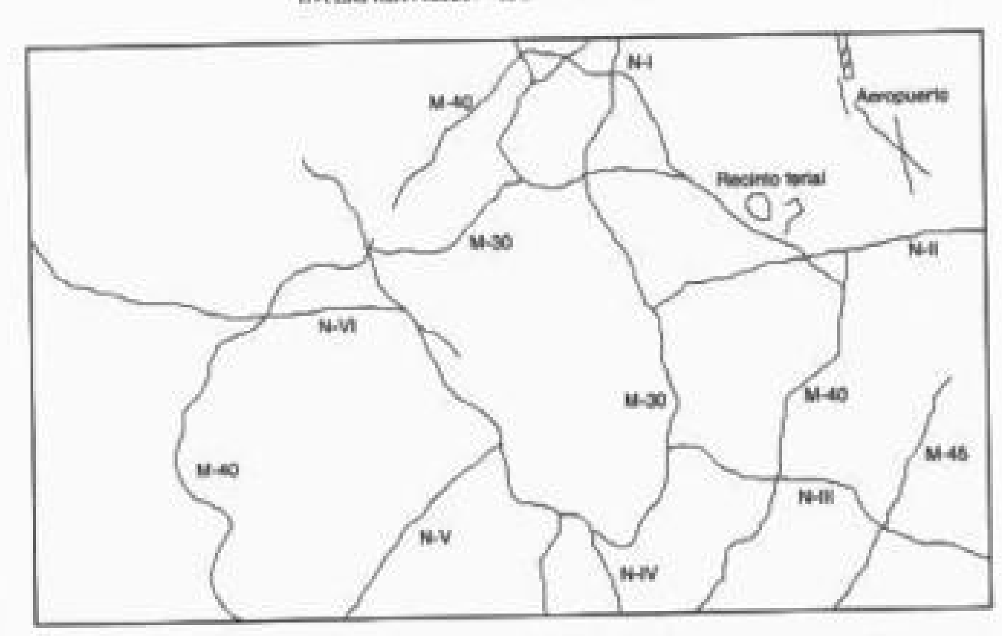


FIG. 5.23. *Croquis de situación de la ciudad de Madrid, con rasgos incluidos en la figura anterior.*

4. Algunos ejemplos de análisis visual

Esta obra no se ha concebido para comentar las múltiples aplicaciones de la teledetección, sino sólo para presentar sus fundamentos. Pese a ello, presentamos algunos ejemplos de análisis visual, a modo de ejercicios, para que el lector compruebe las posibilidades de este tipo de interpretación.

4.1. CARTOGRAFÍA GEOLÓGICA

A partir de imágenes espaciales pueden detectarse rasgos geológicos de gran radio de cobertura. Un buen ejemplo sería el descubrimiento del abombamiento transversal del bloque meseteño, determinado por Alía y colaboradores a partir del análisis visual de las primeras imágenes Landsat disponibles en nuestro país (Alía *et al.*, 1976). Junto a estos fenómenos de conjunto, merecen destacarse otros aspectos más parciales, como son la cartografía de lineamientos, el estudio de erupciones volcánicas, la localización de acuíferos o de yacimientos minerales, y el seguimiento de la dinámica fluvial.

De estos aspectos, la cartografía de alineaciones ha sido el más profusamente empleado en análisis visual. Por alineación o lineamiento se entiende cualquier «rasgo lineal, simple o compuesto, de una superficie, que difiere claramente de los rasgos adyacentes y previsiblemente refleja fenómenos del subsuelo» (Moore y Waltz, 1983). Estos rasgos pueden reconocerse visualmente, a partir de la imagen original o, mejor aún, tras aplicarle alguna técnica de realce. Una vez reconocidos, pueden realizarse

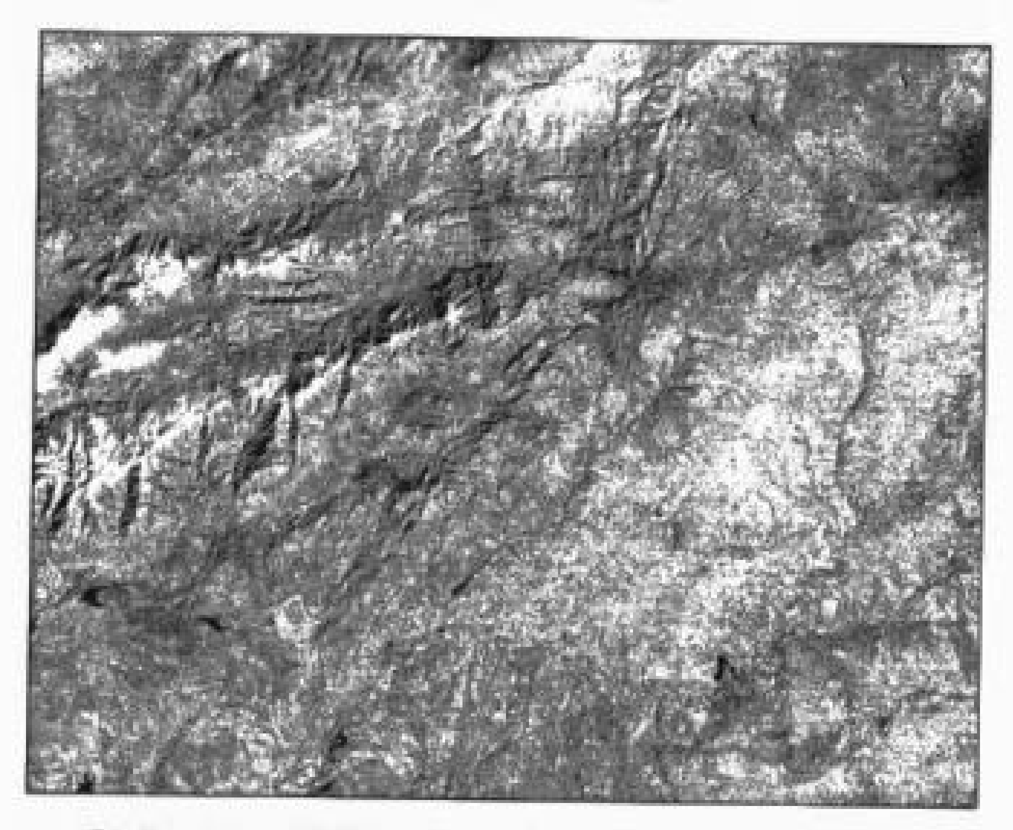


FIG. 5.24. *Imagen MSS de la región central española adquirida en enero de 1981.* (Banda IRC.)

gráficos de frecuencia, indicando las direcciones dominantes, lo que nos permite ponerlos en relación con la estructura geológica de la zona.

Tomemos, como ejemplo, la imagen MSS que incluye la figura 5.24, correspondiente a un amplio sector del centro de España. Con ayuda de un transparente, a partir de ella pueden dibujarse todos los lineamientos reconocibles sobre la imagen (fig. 5.25). Las direcciones dominantes están claramente relacionadas con la tectónica general de la zona.[3] Este ejercicio pasa por reflexionar, en primer lugar, sobre la estación y banda espectral más idónea para este tipo de cartografía. Respecto a la banda del espectro más conveniente para esta aplicación, se recomienda utilizar la correspondiente al IRC (banda 7 en el sensor MSS), pues los lineamientos suelen asociarse con concentraciones de humedad, nítidamente visibles en esta región del espectro. Similares trabajos se han planteado por otros autores, tanto sobre imágenes Landsat (Short, 1982, pp. 118-131; Alía *et al.*, 1976), como sobre imágenes radar (Calvet y Pascual, 1987; Woldai, 1983).

3. Puede consultarse como referencia el Mapa Geológico Nacional a escala 1:1.000.000, así como la serie geológica de mayor escala (1:200.000 y 1:50.000). Entre la bibliografía de referencia, basta acudir a Terán, Solé y otros: *Geografía General de España*, Ariel, Barcelona (varias ediciones).

4.2. Cobertura del suelo

Este término engloba un amplio rango de aplicaciones. Por cobertura del suelo entendemos el tipo de ocupación existente sobre él, ya sea ésta vegetación natural, cultivos agrícolas o espacios urbanos. Este tipo de cartografía resulta básica en la planificación del territorio, ya que es preciso conocer la dedicación actual del terreno para proponer cualquier mejora. Con las ideas vistas en el capítulo 4, conviene organizar una leyenda coherente, a la zona y al propósito del estudio, que guíe los trabajos de interpretación visual.

Con estas ideas, el lector interesado puede ensayar una cartografía de la ocupación del suelo a partir de las imágenes en falso color que aparecen en el CD-ROM. Con ayuda de unos transparentes, se tratará de ir delimitando manchas de color homogéneas, que luego pueden identificarse sobre cartografía de apoyo, fotografía aérea o trabajos de campo. Sería recomendable, al menos, discriminar las siguientes categorías: perennifolios, caducifolios, matorral, pastizales, zona urbana densa, zona residencial exenta, cultivos de secano, suelos y láminas de agua.

El análisis visual se ha empleado en numerosos trabajos referidos a la cobertura del suelo. Las áreas más desarrolladas han sido la cartografía de especies forestales (Marx y Hildebrandt, 1978; Morain y Klankamsorn, 1978; Sadar *et al.*, 1982), la estra-



FIG. 5.25. *Croquis de lineamientos realizado a partir de la interpretación visual de la fig. 5.24.*

tificación fisiográfica (Astaras, 1984; Hilwig, 1980; Nikolaus, 1988), y propiamente la cartografía de ocupación del suelo (Chicharro, 1978; Chicharro y Martínez, 1992; Chuvieco y Martínez Vega, 1990; Harnapp, 1978). Por su alcance europeo, merece especial atención en este sentido la cartografía de ocupación del suelo de los países miembros de la Unión Europea a escala 1:100.000 (proyecto *CORINE-Land Cover*), realizada a partir del análisis visual de imágenes Landsat y SPOT (European Commission, 1993; López Vizoso, 1989*a*).

Un ejemplo de la variedad de criterios visuales que incluye la discriminación de las cubiertas del suelo puede seguirse en un trabajo de este tipo desarrollado sobre la zona centro (Chuvieco y Martínez Vega, 1990). Para este caso se emplearon en la interpretación los siguientes elementos: brillo, color, textura, emplazamiento y alternancia estacional. El trabajo pretendía realizar una cartografía de la cobertura del suelo a escala 1:250.000 sobre dos imágenes TM, de mayo y agosto. En el ensayo cartográfico se delimitaron catorce categorías: espacios urbanos densos, áreas residenciales, parques urbanos, herbáceos de secano, olivar-viñedo, cultivos de regadío, suelos no cultivados, bosques de caducifolias y de perennifolias, praderas, pastos y matorrales, superficie improductiva y agua. Algunas de estas categorías fueron claramente discriminables a partir de su coloración en la imagen de agosto, utilizada como referencia. Se trataba del agua, bosques de perennifolios y matorral. Otras se delinearon tras comparar esta imagen con la de mayo: suelos no cultivados, zona urbana densa, praderas, olivar-viñedo. El resto exigieron una conjunción de diversos criterios. Estas categorías problemáticas fueron: caducifolios, cultivos regados, urbanizaciones residenciales y parques urbanos. En este punto se puso en evidencia el interés de contar con otros criterios visuales de identificación (fig. 5.26). La textura permitió aislar las áreas residenciales, mucho más heterogéneas que el resto de las arriba indicadas. El contexto espacial permitió separar los parques urbanos, claramente identificables por su situación. Por último, la dimensión estacional facilitó la discriminación de los cultivos regados frente a los caducifolios, ya presentes en el suelo en la imagen de mayo.

4.3. Morfología urbana

Teniendo en cuenta la gran complejidad espacial del fenómeno urbano, en donde conviven actividades muy variadas sobre un reducido espacio, la aplicación de la teledetección espacial a estos ámbitos es reciente y aún limitada, si bien se ha visto notablemente beneficiada por la puesta en órbita de los sensores de alta resolución espacial.

Hasta la puesta en órbita de estos equipos los estudios urbanos con teledetección se centraron sobre áreas remotas, en donde la cartografía disponible es inadecuada. Trabajos de este tipo son los emprendidos sobre Nigeria (Adeniyi, 1987; Olorunfemi, 1987) o China (Lo y Welch, 1977). Incluso en países más desarrollados, la cartografía de zonas urbanas ofrece importantes problemas de actualización, debido al dinamismo que normalmente presentan. La cobertura temporal de las imágenes espaciales estimula su empleo en tareas de actualización, ya sea de los límites censales (Dietrich y Lachowski, 1978), ya del espacio edificado (Carter y Stow, 1979; Herrera, 2001; Jensen *et al.*, 1983; Molina y Chuvieco, 1997). Las aplicaciones futuras serán mucho más beneficiosas, al contar con la resolución adecuada a este tipo de estudios (Bauer y Steinnocher, 2001; Hazel, 2001; Schiewe *et al.*, 2001; Smits y Annoni, 1999).

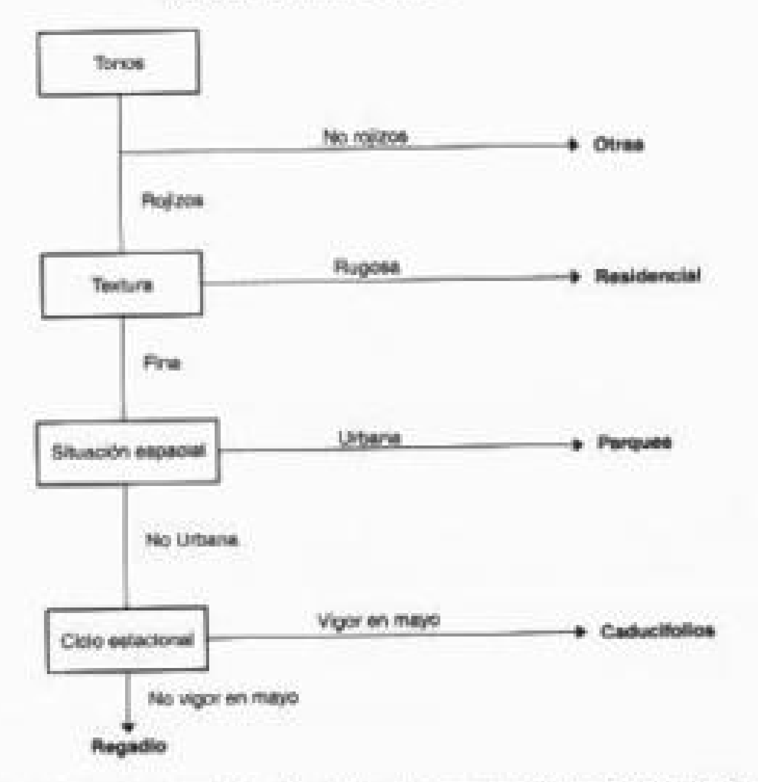


FIG. 5.26. *Un ejemplo de clave jerárquica para organizar criterios visuales en la interpretación de imágenes.* (Tomado de Chuvieco y Martínez, 1990.)

El análisis de la imagen para inferir rasgos de la morfología urbana requiere utilizar criterios mixtos, integrando brillo, color, textura y emplazamiento. A partir del primero puede deducirse la densidad de edificación, por cuanto aquellas zonas que alberguen menor influencia del trazado viario ofrecerán un brillo más oscuro. Asimismo, el color indica si la zona cuenta o no con espacios verdes, bien sea continuos (manchas uniformes), bien discontinuos (en tinte rojo salpicado en medio de los azules propios de la edificación en caso de tratarse de una composición en falso color convencional). En cuanto a la textura, indica el grado de mezcolanza propio de un determinado sector. A partir de estos dos criterios puede ensayarse una delimitación de sectores morfológicos dentro de una zona urbana (Casas y Chuvieco, 1987). Ejercicios didácticos de este tipo se han planteado por varios autores (Chicharro y Martínez, 1992; Chuvieco y Sancho, 1986).

CAPÍTULO 6

ANÁLISIS DIGITAL DE IMÁGENES: CORRECCIONES Y REALCES

«El desarrollo no comienza con los bienes; comienza con la gente y su educación, organización y disciplina.»

E. J. SCHUMACHER, *Lo pequeño es hermoso*

1. La matriz de datos en una imagen digital

Como se comentó previamente, el proceso de adquisición de una imagen digital difiere, sustancialmente, del empleado en la fotografía aérea. En cualquier sistema fotográfico, la energía procedente de los objetos se registra sobre una superficie sensible a la luz. Ésta puede componerse de una o varias capas, formando, respectivamente, una película pancromática o en color.

En el caso de los equipos óptico-electrónicos no existe esta superficie sólida de grabación. El sensor explora secuencialmente la superficie terrestre, adquiriendo —a intervalos regulares— la radiación que proviene de los objetos sobre ella situados. La radiancia recibida estará en función de las características de la parcela del terreno que observa el sensor en cada instante, y el tamaño de ésta será una función de la resolución espacial del sensor. La imagen finalmente almacenada corresponderá a una traducción numérica de esa radiancia (fig. 6.1).

Cada una de las parcelas en las que se divide el territorio observado constituyen la unidad mínima de información en la imagen, que se denomina píxel (del inglés *picture element*, elemento pictórico). En términos sencillos, podemos identificar un píxel como cada uno de los pequeños cuadrados que forman una imagen, visibles cuando se amplía (fig. 6.2). El nivel de gris (o de color si se mezclan tres bandas) con el que aparece cada píxel en el monitor se define por un valor numérico, que corresponde a la codificación de la radiancia que realiza el sensor cuando adquiere la imagen. Este valor numérico se denominará, a partir de aquí, *Nivel Digital* (ND). El nombre se justifica por tratarse de un valor numérico, no visual, pero que puede fácilmente traducirse a una intensidad visual o, si se prefiere, a un nivel de gris, mediante cualquier convertidor digital-analógico (un monitor de visualización, por ejemplo). Cuando se visualiza

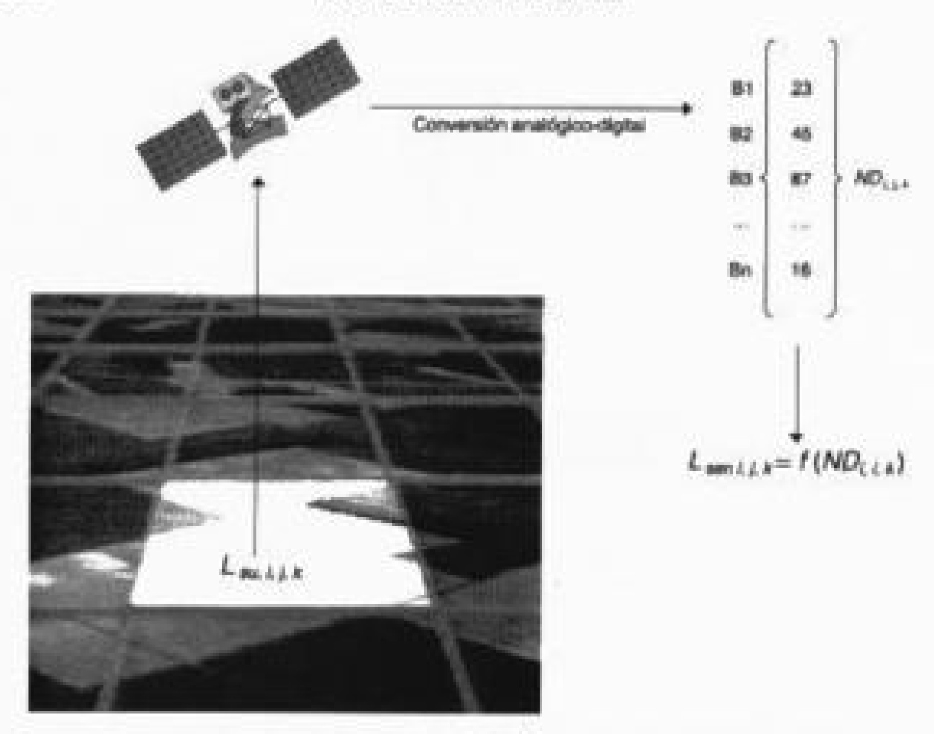


FIG. 6.1. *Diagrama que ilustra el proceso de adquisición de una imagen digital.*

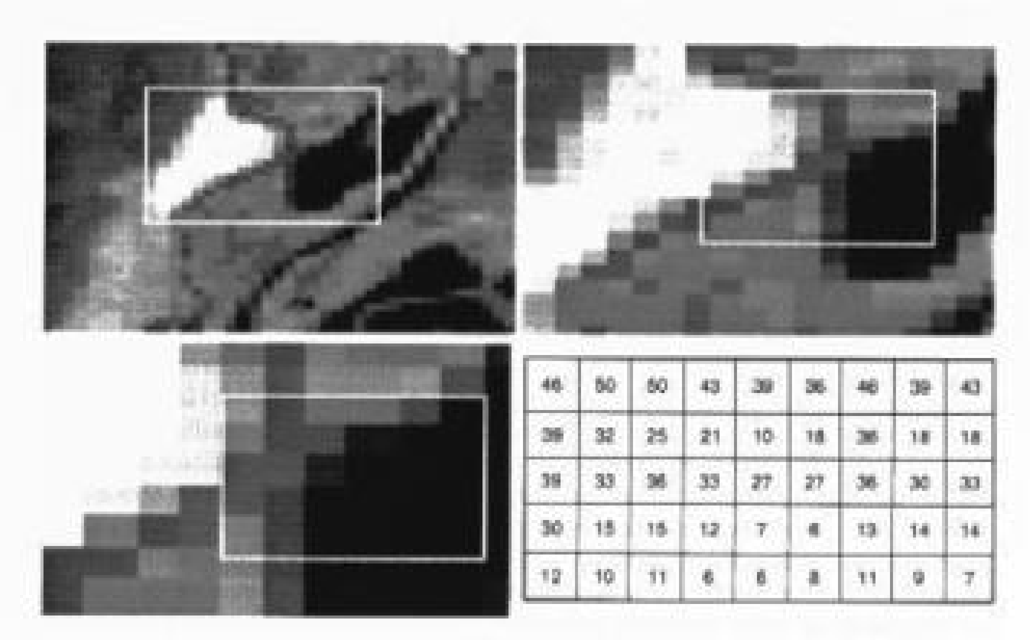


FIG. 6.2. *Una imagen digital está formada por elementos pictóricos (píxeles) codificados por un valor numérico.*

un píxel, la intensidad de gris o de color con la que aparece en el monitor depende de su ND; la relación entre ambos puede modificarse a voluntad del intérprete, de cara a mejorar la calidad visual de la imagen, como veremos más adelante (5.1). En ese sentido, conviene distinguir el ND de cada píxel, el original adquirido por el sensor y almacenado en la imagen bruta, y su nivel visual (NV) que corresponde a la intensidad de gris o color con que se visualiza ese píxel en el monitor. Normalmente, los NV son efímeros, ya que sólo se utilizan para operaciones de realce e interpretación visual de la imagen, mientras los ND forman la base para las operaciones de interpretación digital, especialmente cuando se intenta relacionar la información adquirida por el sensor con algún parámetro físico (reflectividad o temperatura, por ejemplo).

El ND se conoce con distintos nombres en la bibliografía anglosajona: *Digital Number* (Lillesand y Kiefer, 1994), *Pixel Value* (Mather, 1987; Hord, 1986), *Brightness Value* (Jensen, 1996), *Grey Level* (Schowengerdt, 1983), o *Digital Count* (Richards, 1993). En nuestro idioma, nos parece más apropiado el término nivel digital (ND) para expresar su significado, por cuanto se trata de un valor (digital) con un claro contenido pictórico (nivel de gris). En resumen, la unidad mínima de información en una imagen digital se denomina *píxel*, definido por un número entero, *ND*, que puede convertirse en una intensidad luminosa o nivel de gris.

Teniendo presentes estas ideas, la organización de los datos en una imagen digital puede esquematizarse en la figura 6.3. Como vemos, se trata de una matriz numérica

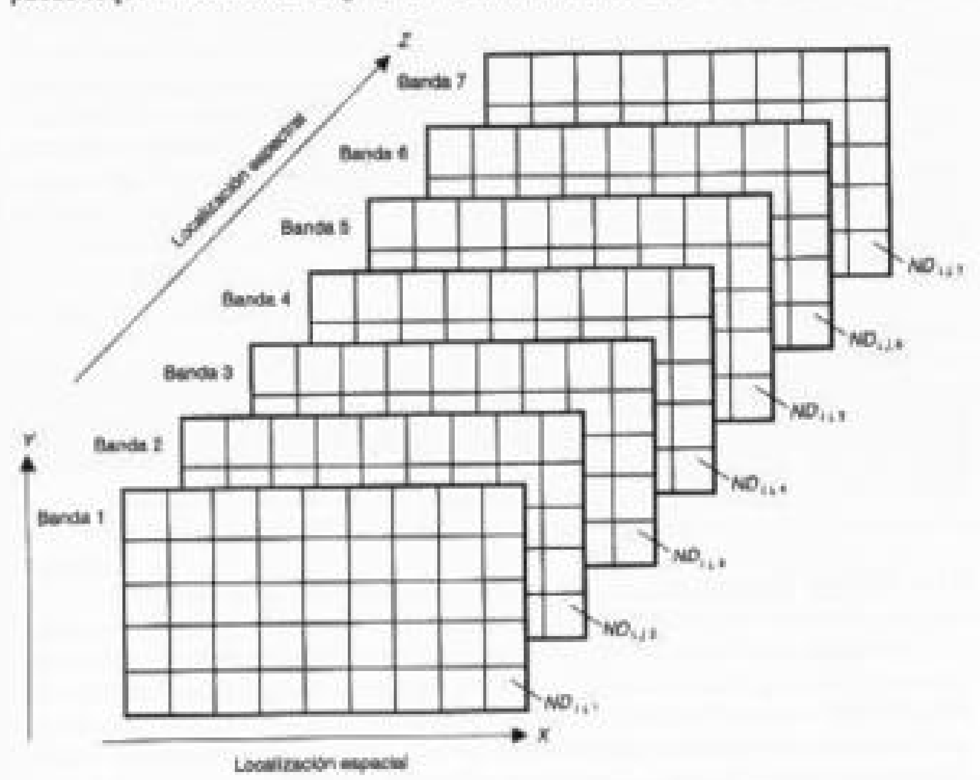


FIG. 6.3. *Organización de datos en una imagen digital.*

de tres dimensiones. Las dos primeras corresponden a las coordenadas geográficas de la imagen, mientras la tercera indica su dimensión espectral. La orientación aproximada Norte-Sur se obtiene variando las filas de la matriz, que normalmente reciben el nombre de líneas *(row, line)*, mientras el recorrido en el sentido de las columnas *(column)* indica la disposición Oeste-Este de la imagen. En esta matriz, el origen de coordenadas se sitúa en la esquina superior-izquierda (línea 1, columna 1), en lugar del borde inferior-izquierdo, como ocurre en cualquier eje cartesiano. Esto es debido a la secuencia de adquisición de imágenes, de Norte a Sur, de acuerdo a la traza del satélite. La tercera dimensión corresponde a la resolución espectral del sensor. Hay tantos planos en la imagen como bandas originalmente detectadas: 36 para el MODIS, 7 para el TM o 5 para el AVHRR.

Considerando ese carácter matricial de cualquier imagen numérica son más fácilmente comprensibles las posteriores transformaciones aplicadas sobre ella. Éstas son, en muchos casos, operaciones estadísticas comunes a otras matrices numéricas. Por ejemplo, en una imagen digital podemos calcular medidas de tendencia central y dispersión (media y desviación típica en cada una de las bandas), cambiar su orientación geométrica (rotación de la matriz), realizar combinaciones aritméticas entre bandas (p. ej., cocientes), sintetizar varias bandas reduciendo la información redundante (componentes principales), o discriminar grupos de ND homogéneos dentro de la matriz (clasificación).

Como es lógico, el análisis digital de imágenes (ADI) se apoya en equipos informáticos adaptados a esta aplicación. Por ello se inicia este capítulo con un repaso de las características y componentes de este tipo de equipos, que van a marcar el rango de posibilidades que se abra, en última instancia, al usuario. Además, se ha introducido un epígrafe previo, dedicado a la estructura de almacenamiento de datos en estas imágenes, con objeto de introducir al lector en el trabajo con este tipo de información numérica.

2. Soporte y organización de la imagen

Cualquier tratamiento digital aplicado a las imágenes requiere que previamente éstas sean introducidas en un sistema informático; dicho de otro modo, que las imágenes sean accesibles al ordenador. Esto depende de los soportes y formatos en los que se ofrecen los ND que definen los píxeles de la imagen.

2.1. Soporte físico de una imagen

Hasta hace unos años, las imágenes de satélite se distribuían de modo casi exclusivo en cintas magnéticas compatibles (CCT). Se trataba de un soporte barato y muy estándar, que era el más apropiado para almacenar un volumen considerable de información. Habitualmente, las cintas tenían 9 pistas *(tracks)*, con una longitud de 2.400 a 3.600 pies. Los principales problemas que planteaba una CCT eran su acceso secuencial, que ralentizaba la lectura de los datos, el alto coste de los equipos lectores y su escasa densidad de almacenamiento frente a las tecnologías actualmente disponibles, por lo que hoy prácticamente han desaparecido del mercado.

Actualmente las imágenes se distribuyen principalmente en CD-ROM y en DVD, que es el medio más compatible y económico de transferir volúmenes considerables de información entre ordenadores. Algunas agencias facilitan también la opción de grabar los datos en cartuchos magnéticos, de acceso secuencial como las antiguas CCT, pero con mucha mayor capacidad (decenas de Gb). Gracias a las mejoras en las velocidades de transferencia de información a través de Internet, también pueden adquirirse imágenes a través de la red, utilizando protocolos de transferencia de archivos (FTP). Éste será, probablemente, el medio más utilizado en el inmediato futuro para la distribución de imágenes, ya que permite su adquisición casi en tiempo real.

2.2. Formatos de grabación

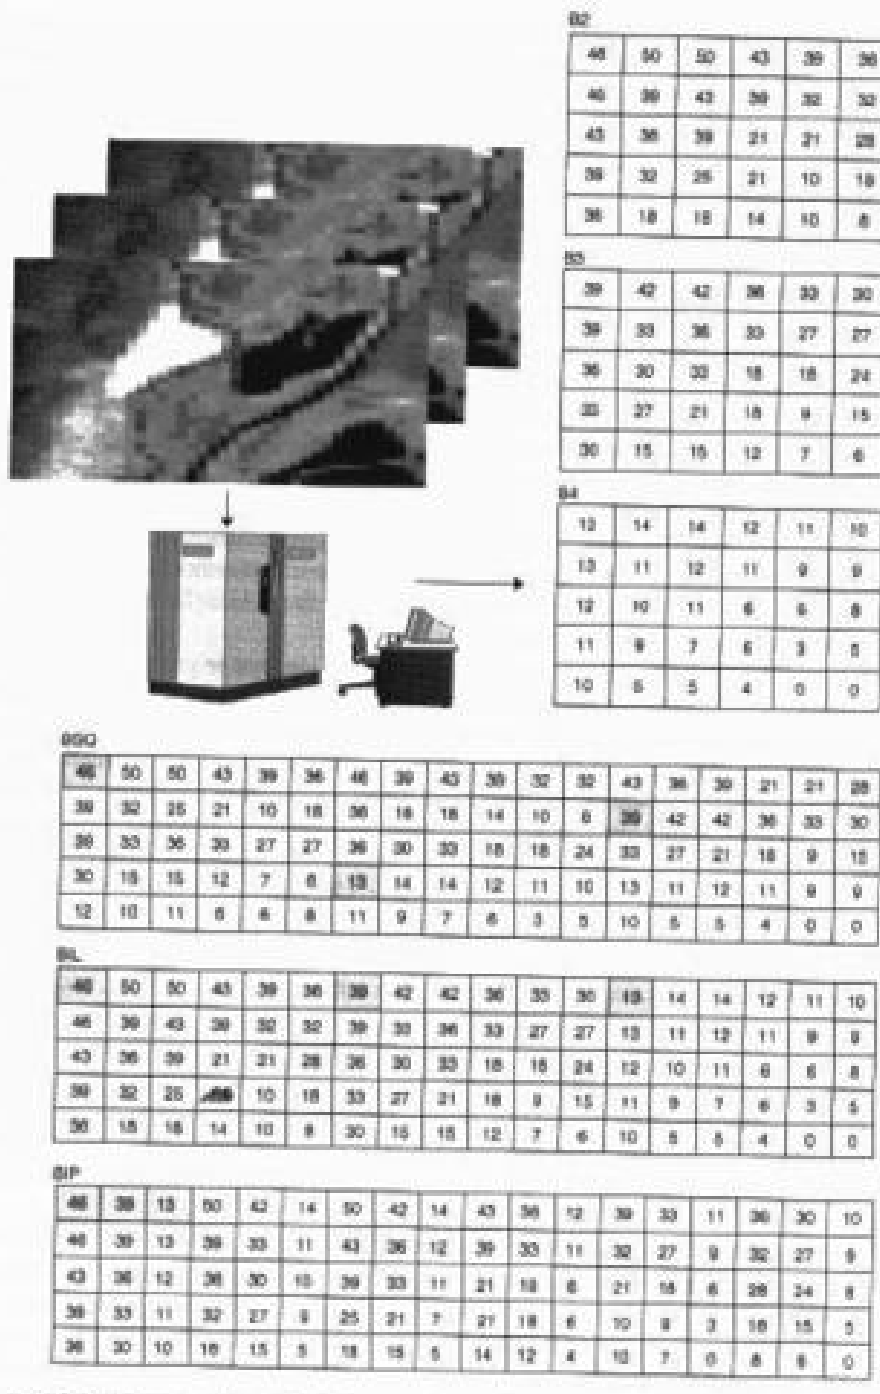
Independientemente del soporte físico de la imagen es necesario conocer el formato de grabación de los datos, de cara a poder reconstruir posteriormente la información detectada por el sensor. En este sentido, conviene considerar la codificación aplicada y la organización lógica de los datos.

En lo que se refiere al primer punto, los ND de la imagen se graban en código binario (como bien es sabido, un bit indica una posición binaria, 0 o 1). La mayor parte de los sensores emplean grupos de 8 bits para almacenar el ND correspondiente a cada píxel. Por ello, cada píxel se define por un *byte*, lo que equivale a un rango de 256 niveles (2^8, de 0 a 255). Éste es también el rango admitido por la práctica totalidad de los equipos de tratamiento digital, por lo que el acceso a las imágenes se simplifica notablemente. En el caso de algunos sensores, como el NOAA-AVHRR o el SAR del ERS, la información se codifica en un rango más amplio (10 y 16 bits, respectivamente), por lo que se requiere una labor previa de compresión de datos para poder visualizar la información en pantalla.

Las imágenes digitales se organizan en una serie de archivos *(files)*, cada uno de los cuales se descompone en registros *(records)*. Normalmente cada imagen incluye un archivo de cabecera *(header file)*, en donde se almacena el formato con el que están grabados los ND que la componen, así como sus condiciones de adquisición (tipo de sensor, localización de la escena, día, elevación y acimut solar, etc.), y, en su caso, el tipo de correcciones aplicadas por la estación receptora. Los registros son de longitud variable, de acuerdo al tipo de archivo y a la organización de los datos en la imagen.

La distribución de los archivos en una escena está en estrecha relación con el formato en que se graban los ND de la imagen. Los tres formatos más habituales son (fig. 6.4):

1. Bandas secuenciales (*Band Sequential*, BSQ). Implica que los ND de cada banda se disponen uno a continuación del otro hasta completar todos los píxeles que la forman. Tras ellos se sitúan los ND de la siguiente banda y así sucesivamente hasta completar todas las bandas espectrales de la imagen. Normalmente, entre banda y ban-



B2

46	50	50	43	39	36
46	39	43	39	32	32
43	36	39	21	21	28
39	32	25	21	10	18
36	18	15	14	10	8

B3

39	42	42	36	33	30
39	33	36	33	27	27
36	30	33	18	18	24
33	27	21	18	9	15
30	15	15	12	7	6

B4

13	14	14	12	11	10
13	11	12	11	9	9
12	10	11	6	6	8
11	9	7	6	3	5
10	8	5	4	0	0

BSQ

46	50	50	43	39	36	46	39	43	39	32	32	43	36	39	21	21	28
39	32	25	21	10	18	36	18	15	14	10	8	39	42	42	36	33	30
39	33	36	33	27	27	36	30	33	18	18	24	33	27	21	18	9	15
30	15	15	12	7	6	13	14	14	12	11	10	13	11	12	11	9	9
12	10	11	6	6	8	11	9	7	6	3	5	10	5	5	4	0	0

BIL

46	50	50	43	39	36	39	42	42	36	33	30	13	14	14	12	11	10
46	39	43	39	32	32	39	33	36	33	27	27	13	11	12	11	9	9
43	36	39	21	21	28	36	30	33	18	18	24	12	10	11	6	6	8
39	32	25	[illegible]	10	18	33	27	21	18	9	15	11	9	7	6	3	5
36	18	15	14	10	8	30	15	15	12	7	6	10	5	5	4	0	0

BIP

46	39	13	50	42	14	50	42	14	43	36	12	39	33	11	36	30	10
46	39	13	39	33	11	43	36	12	39	33	11	32	27	9	32	27	9
43	36	12	36	30	10	39	33	11	21	18	6	21	18	6	28	24	8
39	33	11	32	27	9	25	21	7	21	18	6	10	9	3	18	15	5
36	30	10	18	15	5	18	15	5	14	12	4	10	7	0	8	6	0

FIG. 6.4. *Formatos de grabación en una imagen digital: BSQ, bandas secuenciales; BIP, bandas intercaladas por línea; BIP, bandas intercaladas por píxel. Los píxeles en gris indican dónde comienza una nueva banda en cada uno de los tres formatos.*

da se inserta un archivo de cola y otro de cabecera, con objeto de identificar la región del espectro sobre la que se está recogiendo información.

2. Bandas intercaladas por línea (*Band Interleaved by Line*, BIL). En este caso, los ND se organizan por líneas en lugar de por bandas, disponiéndose consecutivamente los correspondientes a todas las bandas, para cada línea, antes de comenzar la línea siguiente. En definitiva, tras los ND de la línea 1, banda 1, se sitúan los correspondientes a la línea 1, banda 2, para luego continuar los de la banda 3, 4, etc., hasta completar el número total de bandas. Tras la primera línea de la última banda se sitúa la segunda línea de la banda 1, de la banda 2, y así sucesivamente.

3. Bandas intercaladas por píxel (*Band Interleaved by Pixel*, BIP). En lugar de alternarse los ND en cada línea, se alternan en cada píxel. Así, tras el ND correspondiente al píxel de la línea 1, columna 1, banda 1, aparece el correspondiente a la línea 1, columna 1, banda 2, seguido del adquirido para la línea 1, columna 1, banda 3, etc. Este formato es, hoy por hoy, poco frecuente, ya que fue ideado para agilizar la clasificación de sub-imágenes, cuando se empleaban equipos de escasa memoria. Este formato se aplicó a la distribución de imágenes en disquetes de 8 pulgadas, para alimentar los primeros equipos diseñados sobre micro-ordenadores.

3. Equipos de análisis digital de imágenes

Si en todos los capítulos de este libro resulta muy complejo mantener actualizado el material que se comenta, la tarea resulta especialmente complicada cuando nos referimos a los componentes físicos y lógicos de un equipo de ADI, ya que la dinámica del mercado resulta realmente vertiginosa. Por esta razón, hemos preferido reducir sustancialmente este epígrafe frente a las ediciones anteriores de esta obra, dejando al lector interesado la labor de poner al día, en el momento que le resulte más necesario, estos aspectos.

La división que realizamos en las pasadas ediciones entre equipos básicos y avanzados sobre ordenador personal, por un lado, y sobre estación de trabajo, por otro, se ha desvanecido bastante, gracias al notable crecimiento de las capacidades de los equipos disponibles. Los avances en los sistemas operativos también han supuesto una creciente convergencia entre ambas plataformas, especialmente con la notable popularidad del Linux (versión UNIX para ordenadores Intel), que permite utilizar programas diseñados para estaciones de trabajo sobre ordenadores personales.

Para abordar convenientemente las principales operaciones del ADI se requieren, como en cualquier otra aplicación informática, una serie de componentes físicos y lógicos. Entre los primeros (fig. 6.5) hay que analizar las unidades de entrada (hoy resultan imprescindibles sólo el teclado y el ratón electrónico o similar), las de almacenamiento y proceso (memorias internas y externas) y las de salida (principalmente el monitor, aunque también una impresora en color). En este momento, los equipos disponibles en la informática personal cuentan, de modo estándar, con memorias internas de 128 Mb, velocidades de proceso superiores a 1 GHz, y almacenamiento en disco por encima de 20 Gb. Los equipos gráficos más estándar están ya siendo los monitores de 17 pulgadas, con un creciente empleo de las tecnologías de plasma líquido, que fa-

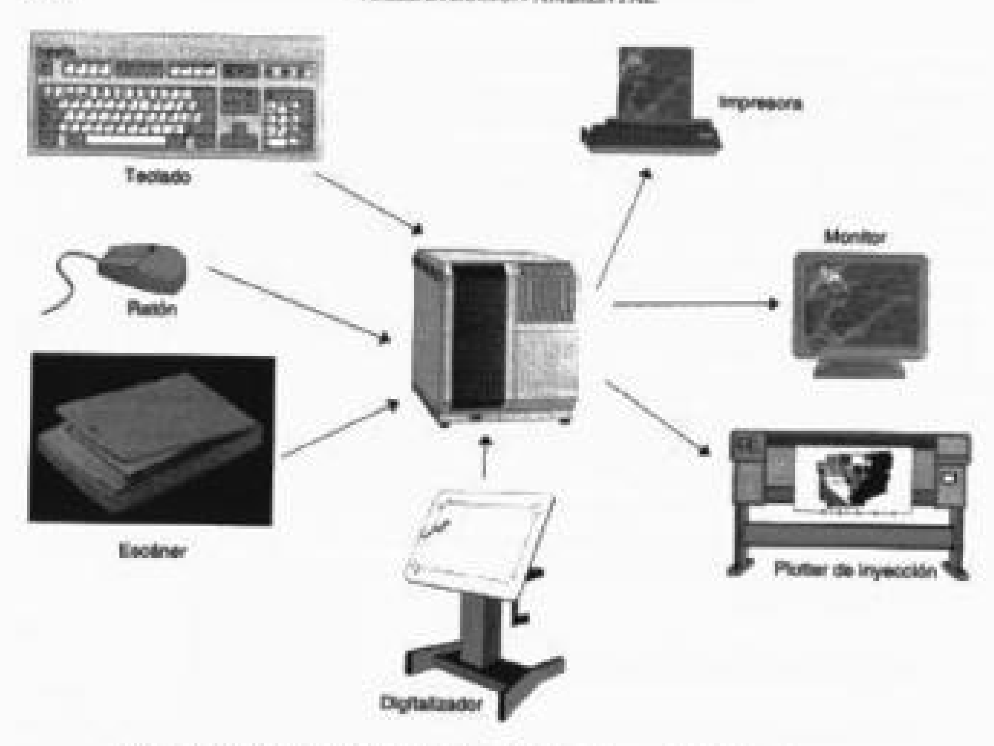


FIG. 6.5. *Componentes de un equipo de tratamiento digital de imágenes.*

cilitan muy buena calidad con menor radiación. Entre los periféricos de salida, conviene citar las impresoras de inyección de tinta, en este momento el estándar en impresión a color, aunque las láser y de sublimación térmica suelen ser más comunes en centros de investigación.

En lo que se refiere al componente lógico *(software)*, suelen distinguirse dos categorías básicas: sistema operativo y programas de aplicación. Como antes comentamos, existe una clara convergencia en lo que se refiere a sistemas operativos. Actualmente podemos dar por desaparecidos algunos (como el VMS, muy utilizado en ordenadores de cierta potencia en los años setenta y ochenta, o el MS-DOS, el primer sistema que instaló IBM en sus ordenadores personales), dominando el mercado los basados en el entorno Windows (principalmente la versión NT y XP) y las diversas versiones de UNIX (principalmente las basadas en entornos de ventanas, Xwindows, y la más reciente Linux, para procesadores Intel).

Los programas de aplicación utilizan los recursos del sistema operativo para comunicarse con el ordenador. Como es bien sabido, el ordenador sólo es capaz de procesar caracteres binarios, por lo que toda instrucción que el usuario pretenda ejecutar ha de ser convertida a este código. Esta tediosa labor la ejecutan los compiladores, programas que convierten una serie de instrucciones más o menos cercanas al lenguaje humano en un código que entienda la máquina. Existen distintos compiladores para cada uno de los lenguajes de programación, y para los sistemas operativos más comunes. Entre los lenguajes más empleados en ADI cabe citar el C (con sus diversas va-

riantes), FORTRAN, Pascal (más recientemente Delphi), Basic (más recientemente *Visual Basic*), IDL y APL.

Ahora bien, lo habitual no será que el usuario redacte sus propios programas, sino que utilice alguno de los muchos disponibles, tanto comerciales como de dominio público. Existe una variada oferta de programas de ADI que ofrecen las operaciones más comunes en este campo, por lo que el intérprete comúnmente sólo tendrá que diseñar sus propios programas cuando sea preciso atender una tarea muy particular, especialmente cuando se trata de una labor de investigación. Estos nuevos desarrollos se facilitan gracias a que casi todos los programas disponen de una cierta capacidad de programación. Puede tratarse de entornos de programación gráficos, que permitan al intérprete seleccionar y encadenar, en el orden que crea conveniente, distintas operaciones que brinda el propio sistema, o bien de librerías de programas, que el usuario pueda engarzar mediante algún lenguaje de programación estándar (Basic, por ejemplo). Finalmente, podría también ofrecerse la posibilidad de enlazar el programa de ADI con rutinas diseñadas fuera del sistema, para realizar operaciones específicas no facilitadas de modo estándar. Por ejemplo, un modulo de clasificación externo al sistema, pero con el que éste pueda compartir formatos.

Las tendencias más recientes de los equipos de ADI mantienen la separación entre *hardware* y *software* (en otras palabras, son programas con configuraciones adaptables), insisten en el entorno amigable al usuario que viene observándose desde los años noventa, garantizan una buena conexión con bases de datos externas (amplia capacidad de exportación/importación de archivos), cuentan con mayor interrelación con los Sistemas de Información Geográfica (SIG, cap. 9), y facilitan entornos más abiertos. Entre los programas comerciales, los más conocidos siguen siendo *ERDAS, PCI-Geomatics, ER-Mapper, Envi e Idrisi* (aunque éste propiamente se considera más un SIG que un programa ADI), mientras entre los de dominio público, disponibles habitualmente en Internet, conviene citar el Multispec, diseñado en la Universidad de Purdue, el SPRING, producido por el Instituto Brasileño de Investigaciones Espaciales (INPE), y el programa GRASS, diseñado inicialmente por el cuerpo de ingenieros militares norteamericano. En el CD-ROM anexo a esta obra se amplía la información de estos programas.

Finalmente, conviene aclarar que no existe un criterio absoluto para elegir entre un sistema y otro. En otras palabras, para evaluar un equipo de ADI habrá que pensar en todo momento en la aplicación a la que se destina. Un usuario con interés en aplicaciones geológicas valorará la capacidad de visualización del equipo, así como las transformaciones y realces que ofrezca. Por el contrario, uno interesado en cartografía de la vegetación o de la cubierta del suelo estará más atento a los algoritmos de clasificación que incorpora. Para uno y otro usuario, sin embargo, convendrá tener en cuenta algunas características generales:

— Rapidez de proceso, en función del lenguaje de programación y de la estructura de los algoritmos empleados. Convendrá anotar los tiempos empleados en realizar operaciones comunes, como sería filtrar o clasificar una ventana de la imagen.

— Diálogo con el usuario. La mayor parte de los equipos más recientes mejoran notablemente la facilidad de manejo, incorporando un sistema de menús y una serie de instrucciones de ayuda en directo al usuario. Convendrá tener en cuenta este aspecto de cara a obtener resultados en el menor tiempo posible.

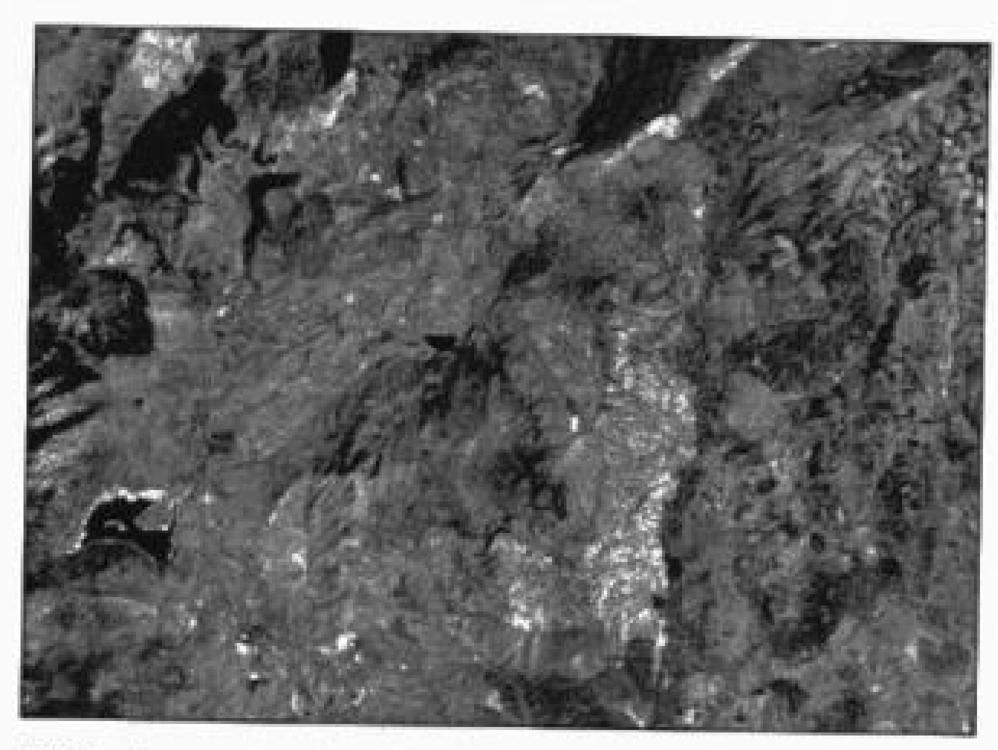


FIG. 6.6. *Imagen correspondiente a la banda 5 del sensor ETM+ sobre la zona de Torrelaguna (15 de marzo de 2000).*

— Capacidades de exportación/importación de archivos, tipo de formatos a los que accede para lectura o escritura, con especial interés en aquellos más estándar.

— Capacidades de programación. Lenguajes macros, librerías o lenguajes de programación disponibles.

4. Operaciones de utilidad general

Se inicia ahora el estudio de las operaciones más comunes en ADI, siempre en el contexto de las aplicaciones de la teledetección espacial.

A lo largo de éste y el siguiente capítulo utilizaremos principalmente una imagen adquirida por el sensor ETM+ del Landsat-7 el 15 de marzo de 2000 (fig. 6.6).[1] Corresponde a un sector situado al norte de la ciudad de Madrid, que incluye las poblaciones de Manzanares y Soto del Real, Miraflores de la Sierra y Torrelaguna. Hemos elegido esta imagen por tratarse de datos relativamente recientes, adquiridos en buenas condiciones de observación, sin cobertura nubosa, y en una zona bastante variada, tanto desde el punto de vista de la topografía (desde 2.000 m en el vértice NW de la zona, hasta los 700 m en el valle del Jarama), como de la ocupación (pinares, caducifolias, pastizales, zonas residenciales, cultivos, matorral, láminas de agua, etc.). Además, se cuenta con imágenes de otras fechas, para realizar comparaciones multitemporales. Elegir una sola imagen para ilustrar las diversas técnicas de análisis digital resulta un arma de doble filo, ya que, por un lado, facilita al lector la comprensión de dicha técnica, al compararla con otras que ya ha visto o va a ver sobre la misma zona. Por otro, puede introducir una cierta monotonía, además de que, en algunos casos, la zona elegida no sea muy apropiada para esclarecer la técnica que se esté comentando. Finalmente, la decisión que hemos tomado es ecléctica: utilizaremos como base una sola imagen, pero se enriquecerá la interpretación con ejemplos de otras imágenes cuando nos parezca apropiado. En el anexo 4 se incluye una referencia más completa de todas las imágenes utilizadas.

1. La zona incluye el área abarcada por la hoja del mapa topográfico nacional denominada Torrelaguna, por lo que en adelante la identificaremos como imagen Torrel00, aunque abarca otros municipios.

Los procesos aplicados sobre esta imagen se basan en varios programas de ADI disponibles en nuestro departamento: ERDAS Imagine, IDRISI y, sobre todo, *PCI-Geomatics*, con el que hemos realizado la mayor parte de las operaciones.[2] El equipo base para el proceso que presentamos es el habitual en un ordenador personal: procesador Pentium III, tarjetas gráficas de 8 Mb, monitor de 17 pulgadas, memoria RAM de 128 Mb y memoria en disco de 5 Gb. Esta descripción no implica, como es lógico, que las operaciones incluidas en el texto sean exclusivas del programa utilizado. Es obvio decir que el empleo de estos equipos no implica un menosprecio hacia otros, sino sólo un aprovechamiento de los recursos disponibles en nuestro departamento.

Se inicia el examen de las técnicas de ADI con procesos que hemos calificado de utilidad general, por cuanto pueden aplicarse a diversas finalidades y sirven de escalón intermedio para otras operaciones más específicas. Se incluyen en este apartado aquellas actividades que se relacionan con la manipulación de archivos, cálculo de estadísticas sobre la imagen y visualización.

4.1. Gestión de archivos

Cualquier sistema de ADI incluye una serie de utilidades generales que le permiten gestionar apropiadamente los archivos donde se alojan las imágenes, polígonos auxiliares y tablas de color, así como las distintas transformaciones que sobre ellas se apliquen. Las más elementales son los comandos propios del sistema operativo, como copiar, cambiar el nombre o eliminar archivos.

Entre las más específicas del ADI, la primera en orden cronológico es la lectura de los datos originales. Esta operación implica contar con un programa que importe los datos en el soporte y formato proporcionados por el organismo distribuidor de las imágenes. Lo ideal es que permita leer la información almacenada en las cabeceras de cada archivo, con objeto de poder importar automáticamente los datos referentes al tamaño de la imagen, condiciones de adquisición y calibración del sensor. También re-

2. Utilizaremos los siguientes módulos del *software* PCI: IW, *Image Works*; XP, *Xpace*; GCP, *GCPWorks*.

sulta muy útil que el programa nos ofrezca la opción de leer una pequeña ventana de la imagen (que incluya el área de interés), extrayendo los ND correspondientes a las bandas originales sobre las que se pretenda trabajar.

Esa labor se facilita si el programa de lectura de imagen incorpora alguna rutina para la visualización del área designada, lo que permite una localización interactiva de las coordenadas inicial y final de esa ventana, agilizando bastante el proceso de búsqueda. Si no se conoce aproximadamente la localización de esa ventana en la imagen resulta conveniente contar con alguna opción para leer la imagen con un factor de reducción, lo que permite visualizar una superficie mayor a la que admitiría la resolución de la pantalla. Esto implica, en definitiva, un muestreo sistemático de la imagen, eligiendo una columna y línea de cada *n*, siendo *n* el factor de reducción. Cuando se ha localizado el área de interés sobre esa zona más amplia puede accederse a aquélla con la plena resolución de la imagen (píxel a píxel).

Una vez leídos los datos, el programa necesita generar una serie de campos para la documentación de la imagen, que le permitirán gestionar posteriormente su visualización y análisis. Para reconocer apropiadamente un archivo de imagen, cualquier programa necesita saber sus dimensiones (número de líneas y columnas), el número de bandas y número de bits por píxel, de otra manera no podrá reconstruir la estructura original de los datos. Además, si la imagen está georreferenciada es preciso conocer los datos de la proyección, las coordenadas de sus vértices y el tamaño del píxel en x e y. Otra información relevante sería la concerniente a las estadísticas de la imagen (descriptivas, histogramas, etc.), y a las condiciones de adquisición.

En algunos programas esa información se asocia permanentemente a la imagen, ocupando los primeros bytes del archivo; en otros se almacena en un archivo auxiliar, con el mismo nombre de la imagen original. Esto facilita la lectura de la imagen por otros programas, ya que el archivo sólo contendrá datos de imagen y no información auxiliar. También en función del programa de tratamiento elegido, los datos pueden almacenarse en formato BSQ o BIL. En el primer caso, cada banda ocupa un archivo distinto, mientras en el segundo todas las bandas se incluyen en el mismo. Esta segunda opción agiliza el cálculo cuando se trata de generar combinaciones entre bandas de la misma imagen, pero lo dificulta si se pretende relacionar información de dos imágenes. En el caso del programa IW, toda la información se graba en el mismo archivo, tanto las bandas detectadas por el sensor, como las estadísticas, documentación, vectores o anotaciones que realice posteriormente el intérprete (fig. 6.7). Esto permite un almacenamiento compacto, en donde todo lo referente a una escena se encuentra disponible en una sola ubicación, pero tiene el problema de generar archivos que pueden llegar a ser muy grandes.

Otra utilidad habitual en los equipos de ADI permite generar una composición de dos o más imágenes, obteniendo una mezcla de información interesante para la representación visual. Basta que un programa sea capaz de leer una imagen o banda y escribir su contenido en aquellas coordenadas de una nueva imagen que le indique el usuario. Por ejemplo, en la figura 6.8 aparece una composición de cuatro bandas correspondientes a un fragmento de la imagen Torrel00, que incluye el embalse de Santillana y el núcleo de Colmenar Viejo. La posibilidad de verlas simultáneamente nos ayuda a interpretar la diversa información espectral que contiene cada una de las bandas originales. Así, las bandas visibles (azul y rojo) presentan un aspecto muy similar, tendien-

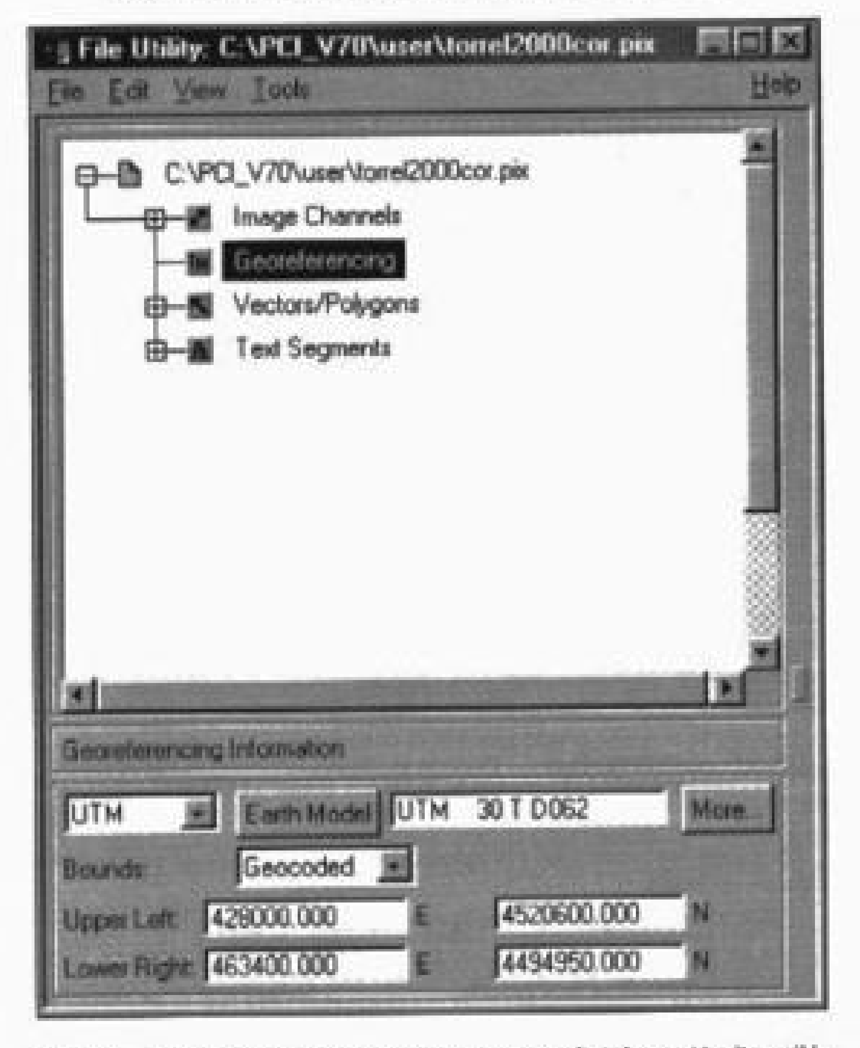


FIG. 6.7. *Panel de utilidades de PCI-IW que muestra la información disponible en una determinada imagen. En este caso se incluyen las bandas originales, vectores auxiliares y coordenadas de referencia.*

do ambas hacia tonos oscuros, con especial contraste entre las zonas urbanas y de vegetación. Por su parte, la banda 4 (IRC) presenta una tonalidad más clara para los pastizales (mayor reflectividad), mientras la 5 (SWIR) ofrece mejor contraste tierra-agua y peor entre zonas construidas y de vegetación natural.

Otra utilidad de interés en ciertas aplicaciones es aislar un sector de la imagen, definido por un polígono irregular, de cara a aplicarle un tratamiento específico. La operación recibe también el nombre de máscara, y se utiliza bastante asiduamente en el contexto de los SIG (por ejemplo, para obtener resultados referidos a una determinada unidad administrativa). El trabajo con sectores irregulares de la imagen implica los siguientes procesos:

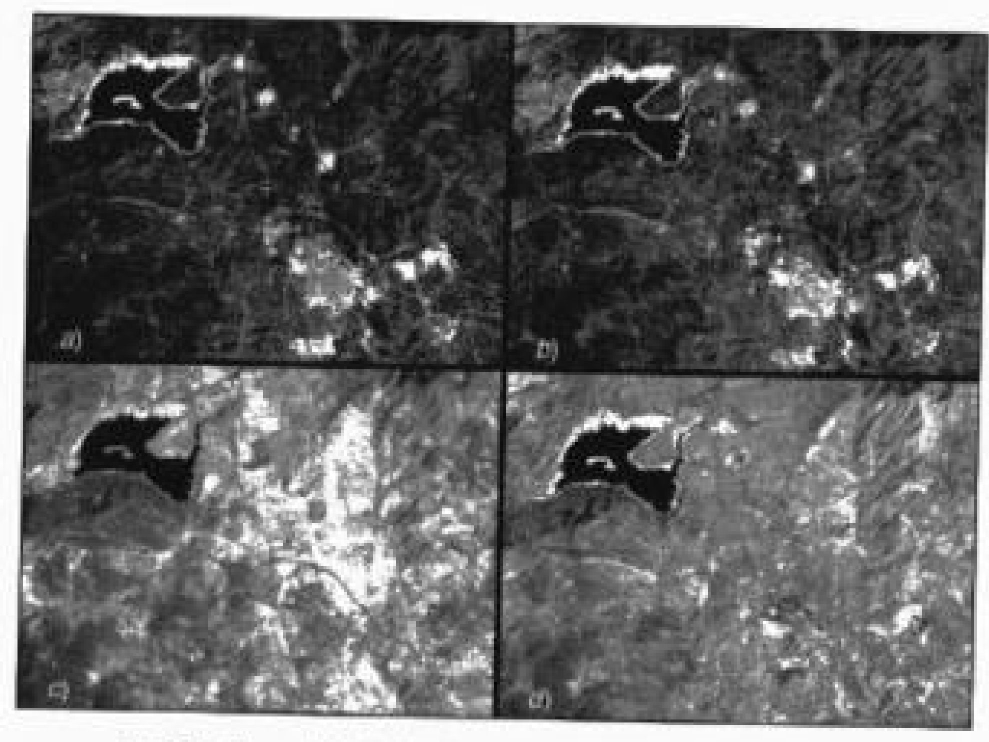


FIG. 6.8. *Composición de 4 bandas de la imagen Torrel00: a) Banda 1 (A); b) Banda 2 (R); c) Banda 4 (IRC), y Banda 5 (SWIR).*

1. Delimitar los límites del polígono deseado, con ayuda de un digitizador, cursor, o ratón electrónico.
2. Aplicar ese polígono a la imagen original, aislando todos aquellos píxeles que se sitúen en el interior de dicho polígono de los que se encuentren fuera. Estos últimos pasarán a tener un ND de 0, por lo que son eliminados de posteriores tratamientos.

La figura 6.9 ilustra la realización de este proceso para la imagen Torrel00. Se ha extraído un sector correspondiente al centro de la ventana, definido por la red local de

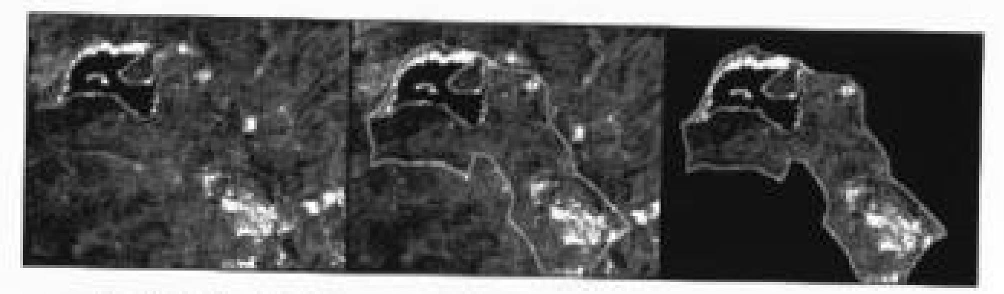


FIG. 6.9. *Ejemplo de máscara aplicada a un sector de la imagen de Torrelaguna.*

carreteras. Tras digitizar el polígono se extrajeron los ND correspondientes a la banda 3 del interior de esa zona, aislándose del resto.

4.2. UTILIDADES PARA LA VISUALIZACIÓN

La capacidad para la visualización de la imagen debe considerarse como una de las principales características de un equipo de ADI. Esa capacidad es dependiente del *hardware* disponible y de las herramientas que ofrece el sistema para «dialogar» con el monitor gráfico. La relación, en este sentido, sería muy amplia, puesto que una de las tendencias de mayor desarrollo, en el momento presente, tiende precisamente a construir sistemas mucho más interactivos con el usuario.

En lo que se refiere al ámbito que nos ocupa, las utilidades de visualización más habituales son:

1. Conversión digital-analógica de los ND almacenados en la imagen, lo que permite su representación en el monitor gráfico. El proceso técnico aplicado puede estudiarse en otras publicaciones (Richards, 1993, apéndice F; Muller, 1988*a*). Basta aquí indicar que supone convertir un valor numérico (el ND de cada píxel) en una señal analógica que se envía a un monitor para su representación visual. Con objeto de que la imagen visualizada se mantenga en el monitor existe un dispositivo intermedio, denominado memoria gráfica o de refresco *(refresh buffer)*, que almacena temporalmente los ND visualizados hasta que se envíe una nueva imagen al monitor. A partir de esa memoria intermedia se produce un barrido del tubo de imagen, a un ritmo de 25 o 30 veces por segundo, suficientemente alto para que no pueda apreciarse por el ojo humano. Lo más habitual es que se cuente con tres memorias de refresco, una para cada uno de los tres colores elementales (RVA), gracias a lo que pueden visualizarse tres bandas simultáneamente.
2. Obtención de coordenadas. Con ayuda del digitizador o del ratón electrónico pueden conocerse las coordenadas de distintos puntos de interés, de cara a la corrección geométrica de la imagen (6.3) o a la caracterización espectral de distintas cubiertas. La localización se facilita por la ayuda de un cursor gráfico, normalmente en forma de cruz o de flecha.
3. Digitización de áreas sobre la imagen, realizada —al igual que en el caso anterior— con la ayuda de un cursor móvil. Estas zonas pueden hacerse corresponder con áreas de entrenamiento para la clasificación (cap. 7, apdo. 2.2), con elementos lineales para anotar los resultados (carreteras o ríos), o con sectores que pretenden aislarse de la imagen (máscaras). En similares términos cabe expresarse en lo que hace referencia a la inclusión de rótulos o simbología gráfica (encabezamientos, flechas de orientación, líneas, retícula U.T.M., etc.), de interés para la presentación cartográfica de los resultados (7.2.4).
4. Cambios de escala, esta operación se dirige a ampliar o reducir la imagen visualizada para verla con mayor o menor detalle, respectivamente. Este proceso se realiza en la memoria de refresco, por lo que se obtiene casi instantáneamente, facilitando la interactividad con el intérprete. Además de aumentar el tamaño del píxel, el usuario puede desplazarse sobre la imagen a esa nueva escala *(pan, roll)*, facilitando notablemente la

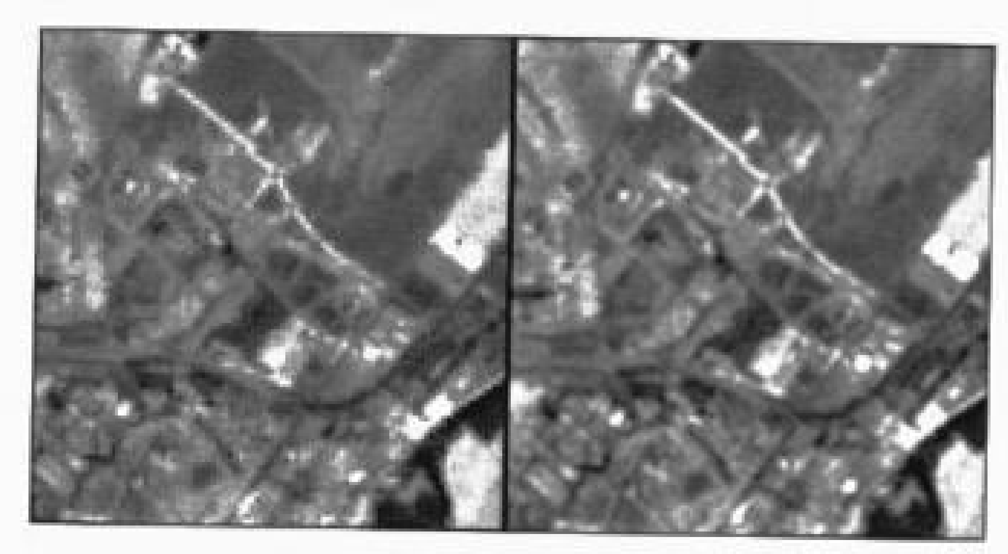


FIG. 6.10. *Comparación entre un zoom por expansión (izquierda) y por interpolación (derecha) sobre una ventana de la imagen Alcala99.*

localización de zonas de interés. Una ampliación de mayor calidad visual puede lograrse mediante un *zoom* interpolado. Aquí, en lugar de una simple réplica de los ND originales, se crea una nueva matriz de tamaño equivalente al nivel de magnificación. En esta matriz se sitúan los ND originales, y se calculan los otros por interpolación lineal de estos valores. La impresión que causa sobre la pantalla es la de una imagen mucho más nítida, puesto que mantiene una mejor transición entre píxeles vecinos (fig. 6.10).[3]

5. Creación de archivos de visualización. En muchas ocasiones resulta muy conveniente contar con una copia de la información almacenada en el monitor. Esto se consigue gracias a un programa auxiliar que salva la memoria de refresco en el disco, generando una nueva imagen que puede visualizarse posteriormente. Por ejemplo, un mosaico de cuatro bandas puede realizarse, además de mediante extracción de los 4 archivos y generación de uno nuevo, mediante una composición interactiva en el monitor. Gracias a ello pueden visualizarse un conjunto de imágenes y/o elementos gráficos asociados, sin necesidad de repetir todo el proceso que llevó a su creación. Conviene tener en cuenta, sin embargo, que en este caso la precisión de los datos depende de la resolución de la memoria gráfica (en ocasiones la imagen tendrá que comprimirse para que puedan visualizarse varias bandas simultáneamente), mientras con la creación de un archivo compuesto se mantiene la resolución original de los datos. Existen numerosos programas en el mercado que permiten capturar la información visualizada en pantalla (o una parte de ella), lo que resulta muy conveniente para fines didácticos.

3. Al igual que ya comentamos en capítulos anteriores, las versiones en color en muchas de las figuras que aparecen en el texto en blanco y negro pueden encontrarse en las presentaciones incluidas en el CD-ROM adjunto a esta obra.

4.3. Cálculo de estadísticas e histograma de la imagen

Ya hemos indicado que cualquier operación aplicada sobre la imagen parte de comprender su carácter digital. Al igual que cualquier variable estadística, la operación más elemental que podemos realizar con una imagen es describir su tendencia central y dispersión. En otras palabras, conocer cuál es la tendencia general de la radiancia detectada en cada banda, y qué nivel de homogeneidad existe entre los píxeles que la componen. Para ello, cualquier programa de ADI facilita el cálculo de las estadísticas elementales de la imagen, al menos de las medidas de tendencia central y dispersión más habituales. Recordando aspectos de estadística descriptiva, la media de una banda k puede definirse como:

$$\overline{ND}_k = \frac{\sum_{i=1,n} ND_{i,k}}{n_k} \qquad [6.1]$$

siendo n el número de píxeles que componen esa imagen, y la desviación típica como:

$$s_k = \sqrt{\frac{\sum_{i=1,n}(ND_{i,k} - \overline{ND}_k)^2}{n_k}} \qquad [6.2]$$

Estas medidas nos ofrecen una primera valoración sobre el carácter de cada una de las bandas y su grado de homogeneidad. Las correspondientes a Torrel00 aparecen en la tabla 6.1.

De esta tabla se deduce que la banda 1 ofrece el mayor desplazamiento de sus ND mínimos, lo que puede ser consecuencia del efecto de dispersión atmosférica, como luego veremos. Los ND medios son más altos para las bandas 4 y 5, bastante saturadas a juzgar por los valores mínimo y máximo, muy próximos a 0 y 255, respectivamente. La banda 5 acoge también la mayor heterogeneidad, aunque no muy distinta de la banda 4. Por su parte, la banda 1 ofrece la menor dispersión. Lógicamente, estos valores numéricos se relacionan con los parámetros de calibración del sensor y con las regiones del espectro que abarca. Como resulta evidente, la banda 5 es la más sensible a alteraciones de radiancia, mientras la 1 ofrece el peor contraste en la escena.

Además de estos valores medios, también resulta de gran interés contar con el histo-

TABLA 6.1. *Estadísticas elementales de la imagen de Torre100*

	Máximo	*Mínimo*	*Media*	*Desv. típica*
Banda 1	247	45	69,26	8,87
Banda 2	236	27	55,63	10,80
Banda 3	255	17	58,05	15,59
Banda 4	255	14	91,13	22,87
Banda 5	255	8	91,86	23,46
Banda 6	255	5	62,21	19,84

Los números refieren a ND. No se ha incluido la banda térmica.

grama de frecuencias de cada banda, que nos informa sobre cómo se distribuyen los ND en una determinada imagen. Con objeto de facilitar la representación del histograma, las frecuencias absolutas suelen convertirse a relativas, de acuerdo a una sencilla fórmula:

$$FR(ND_i) = \frac{F(ND_i)}{\sum_{i=1,m} F(ND_i)} \qquad [6.3]$$

siendo m el número de niveles digitales de esa banda.

Esto es, la frecuencia relativa de un determinado ND (p. ej., el valor 123) se calcula como el cociente entre el número de píxeles que presentan ese valor y el total de píxeles de la imagen. Esa proporción sirve para escalar el histograma, a partir de la frecuencia relativa mayor.

Varios autores han puesto de relieve el interés del histograma para realizar una primera valoración de la imagen (Castleman, 1978; Jensen, 1996). Su localización nos permite deducir la tonalidad dominante de cada banda; su anchura está relacionada con el contraste, mientras la presencia de picos relativos puede ser testigo de determinadas clases de cobertura. Por ejemplo, para el caso de la imagen de nuestro ejemplo, los histogramas de los ND (fig. 6.11) nos permiten realizar algunos comen-

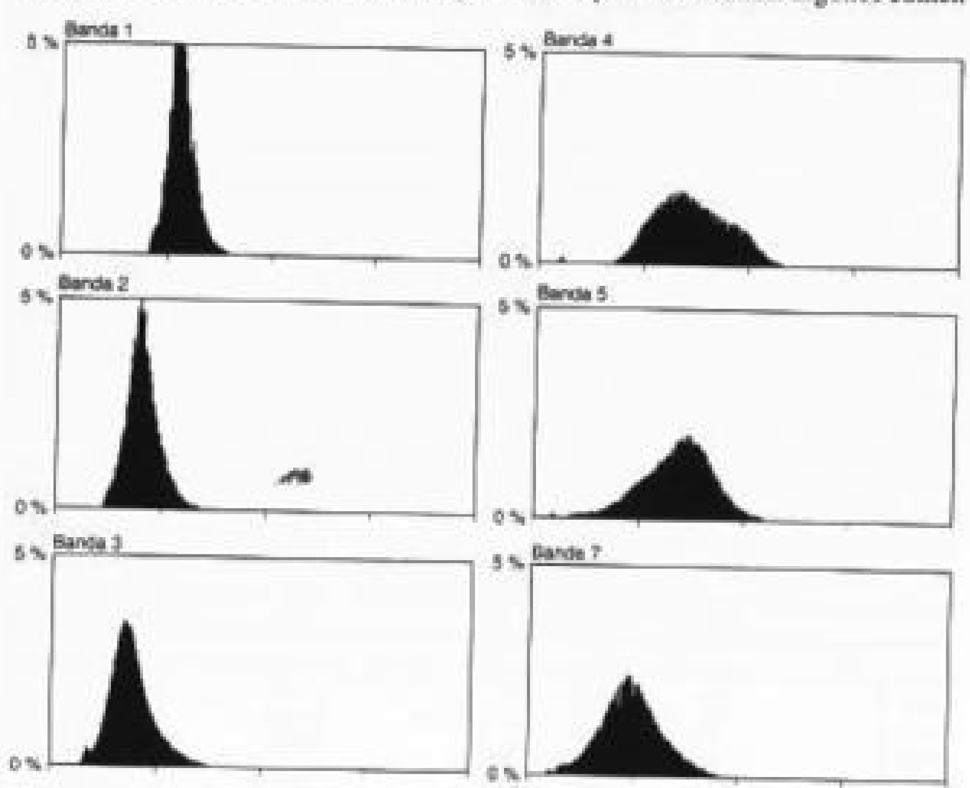


FIG. 6.11. *Histogramas de las bandas ópticas de la imagen de Torrelaguna. La escala horizontal va de 0 a 255.*

tarios interesantes. Por un lado, todos ellos ocupan sólo un pequeño margen del rango de variación ofrecido por el sensor, o, si se prefiere, por el equipo de visualización (0 a 255). Esto implica la conveniencia de ajustar, de alguna forma, la variación inicial a la máxima permitida, lo que supondrá una mejora del contraste (ver 5.1). Entre las bandas aquí incluidas, la 4 y la 5 se confirman como las que ofrecen mayor dispersión (recuérdese que poseen la desviación típica más alta), mientras la 1 y la 2 presentan el histograma más estrecho. En cuanto al significado de los distintos picos de frecuencia, resulta muy complicado identificar las cubiertas que los originan. En otros casos puede resultar más sencillo; por ejemplo, el mínimo relativo observado en las bandas 4 a 7, en los valores más bajos, parece lógico que corresponda a las áreas inundadas por embalses, ya que en esta banda el agua presenta su máxima absorción.

Además de la consideración de cada banda por separado, también resulta de interés tener en cuenta las relaciones entre bandas, con objeto de analizar el grado de información original que aporta cada una. Este análisis puede realizarse gráficamente, mediante la construcción de dispersogramas, que presentan en un gráfico bivariado la localización de los píxeles de la imagen a partir de sus ND en dos bandas. Cuando la nube de puntos en estos gráficos tiendan a formar una línea (o una elipse de ejes muy contrastados), las dos bandas tenderán a estar muy relacionadas. En otras palabras, puede ser suficiente trabajar con una de ellas reteniendo la mayor parte de la información original. Esto ocurre, típicamente, entre las bandas visibles (1, 2 o 3) o las situadas en el SWIR (5 y 7). Por el contrario, si la nube de puntos ofrece alta dispersión, la relación entre las bandas será pequeña o, lo que es lo mismo, las dos ofrecen información contrastada y ambas son de interés para el análisis, como ocurre con la relación entre el IRC y el VIS. Por ejemplo, en la figura 6.12 se recoge la correlación gráfica entre las bandas 1-2 y 3-4 de nuestra imagen de ejemplo. Las dos primeras se sitúan en el espectro visible, y tienen una elevada correlación, pues muchas cubiertas terrestres poseen una reflectividad muy similar entre ellas. En consecuencia, la nube de puntos tiende a presentar una forma muy alargada. Por el contrario, entre las bandas 3 y 4 (R e IRC) existe mucha menor similitud, al tratarse de dos bandas con mayor contraste espectral, especialmente en lo que se refiere a las cubiertas vegetales (alta reflectividad en la 4, baja en la 3). En consecuencia, a partir del análisis de la nube de puntos podemos incluso distinguir algunas cubiertas: bajos ND en las dos (A en la fig. 6.12) identificarán al agua; bajos en la 3 y altos en la 4 identificará la vegetación (B), y altos en las dos, identificarán el suelo (C).

Este análisis gráfico se completa con el cálculo de algún índice numérico de la relación entre bandas. Uno de los más empleados es el coeficiente de correlación lineal de Pearson, definido como el cociente entre la covarianza de las dos bandas d y f y el producto de sus desviaciones típicas:

$$r_{d,f} = \frac{\left(\sum_{i=1,n}(ND_{d,i} - \overline{ND}_d)(ND_{f,i} - \overline{ND}_f)\right)/n}{s_d\, s_f} \qquad [6.4]$$

de sentido análogo a los símbolos incluidos en [6.1] y [6.2]. En este caso, la correlación entre las bandas incluidas en la figura 6.12 ofrece un valor alto, como es espera-

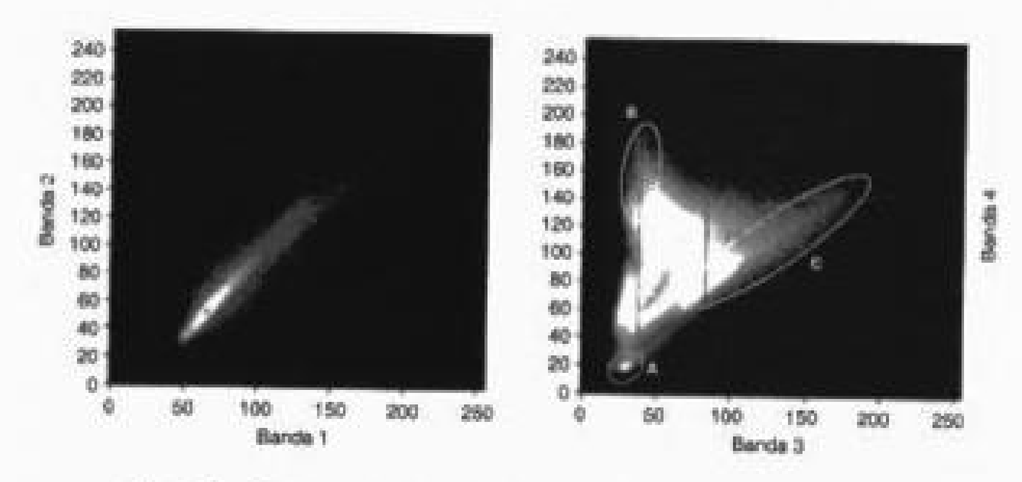


FIG. 6.12. *Diagramas de dispersión de las bandas 1-2 (izqda.) y 3-4 (dcha.).*

ble, entre la 1 y la 3 ($r = 0{,}952$), mientras la 3 y la 4 muestran una correlación mucho más baja ($r = 0{,}248$).

Otro aspecto que puede ayudar a entender la radiometría de la imagen es la construcción de perfiles espectrales. La técnica parte de digitizar sobre la imagen una línea que recoja las cubiertas que quieren inspeccionarse, de cara a analizar la variación espacial de los ND en las distintas bandas. En nuestro caso, hemos seleccionado un pequeño transecto que atraviesa un sector de agua (el embalse de Santillana), un banco de arena, apenas perceptible, y una zona de pastizal, bastante vigoroso en esta época del año (fig. 6.13). Las tres bandas parten de valores bajos, identificando al agua, para

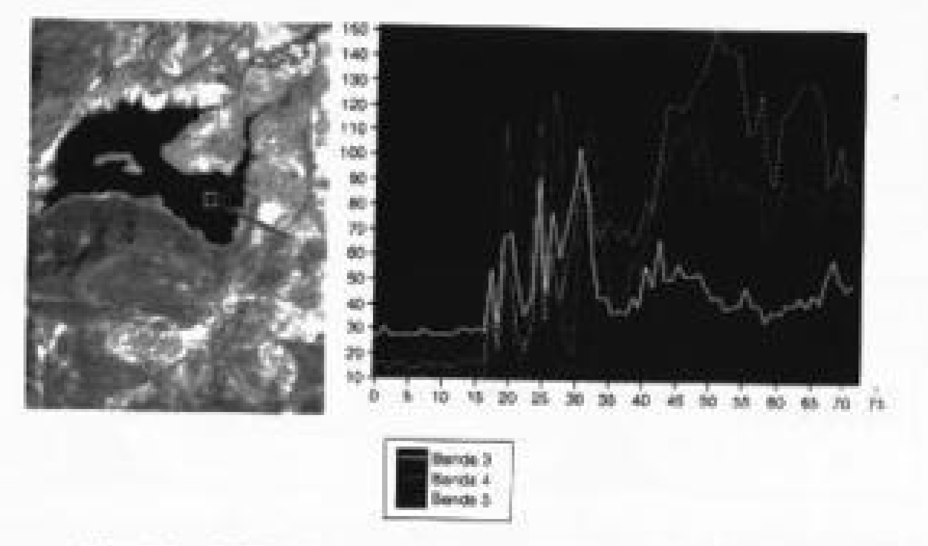


FIG. 6.13. *Perfil radiométrico sobre una ventana de la imagen Torrel00.*

ir aumentando según cruzan otros tipos de cobertura. Cuando se trata de suelos descubiertos, las tres suben al unísono, mientras que lo hace con mayor intensidad la banda 4 cuando atravesamos una zona de mayor actividad clorofílica, que presentará absorción en la banda 3 y, en menor medida, en la 5.

5. Realces y mejoras visuales

En este capítulo se consideran aquellas técnicas dirigidas hacia la mejora de la calidad visual de la imagen. Tratan de disponer mejor los datos para su análisis visual, de tal forma que sean más evidentes los rasgos de interés que presenta la imagen. Se incluyen en este apartado los procesos de mejora del contraste, composiciones coloreadas, cambios de escala, y filtrajes.

5.1. AJUSTE DEL CONTRASTE

Los procesos de ajuste del contraste tienden a adaptar la resolución radiométrica de la imagen a la capacidad del monitor de visualización. Como ya vimos anteriormente, cada sensor codifica la radiancia recibida en un número determinado de ND, de acuerdo a las características de su diseño. Ese rango digital puede no corresponder con el número de niveles visuales (NV) que facilita la memoria gráfica, por lo que resulta preciso ajustar, por algún procedimiento, ambos parámetros. En este sentido, caben dos situaciones obvias: 1) que el rango de ND de la imagen sea menor que el de NV facilitado por el sistema de visualización, y 2) que la imagen presente un mayor número de ND que posibles NV. En el primer caso se deberá aplicar una expansión del contraste original, mientras en el segundo una reducción del mismo.

La idea de contraste digital puede ilustrarse con un símil fotográfico. Una fotografía aparece con poco contraste, desvaída, cuando no existe una gran diferencia entre sus tonos más claros y más oscuros. De la misma forma, podemos definir digitalmente el contraste por relación a los ND máximo y mínimo de una imagen. Tal definición puede apoyarse en cualquiera de las medidas de dispersión comúnmente utilizadas en estadística (Schowengerdt, 1983):

$$C_1 = ND_{max} / ND_{min} \quad [6.5]$$

$$C_2 = ND_{max} - ND_{min} \quad [6.6]$$

$$C_3 = s_{ND} \quad [6.7]$$

Aquí aparecen tres definiciones digitales del contraste: el cociente entre el valor máximo y el mínimo, el rango, y la desviación típica de los ND de la imagen. A partir de estas medidas puede juzgarse la necesidad de expandir o comprimir el contraste, en función de las capacidades de visualización ofrecidas por el sistema. Hasta el momento, el primer proceso ha sido empleado rutinariamente en la mayor parte de las aplicaciones. En cuanto a la compresión del contraste, resulta una materia de creciente interés con objeto de reducir el volumen de almacenamiento de

las imágenes y aprovechar íntegramente los equipos de visualización de bajo coste. A continuación se presentan con mayor detalle ambos procesos. Se inicia ese comentario con el análisis de la técnica que permite aplicarlos operativamente: el diseño y empleo de las tablas de color.

5.1.1. *Tablas de referencia del color*

Una tabla de referencia del color (*Color Look Up Table*, CLUT), o simplemente tabla de color, es una matriz numérica que indica el nivel visual (NV) con el que se representa en pantalla cada uno de los ND de la imagen. La CLUT se inserta entre la memoria de refresco y el tubo de imagen del monitor, lo que permite modificar la relación entre el ND almacenado en disco y la intensidad de brillo con que se visualiza (NV). En otras palabras, ambos valores no tienen por qué ser iguales.

En la mayor parte de los equipos de ADI, la CLUT es una matriz numérica de 3 columnas por 256 filas (ya que el rango de codificación va de 0 a 255). El orden de la fila indica el ND de entrada, mientras el almacenado en la tabla expresa el nivel visual (NV), con el que ese ND será representado en pantalla. Las tres columnas corresponden a los tres colores elementales (RVA: fig. 6.14*a*).

Conviene recordar que los equipos de ADI utilizan el proceso aditivo de formación del color, por lo que cuanto mayores sean los valores de NV en cada columna, mayor componente de RVA tendrá el píxel finalmente visualizado. Caso de que se esté manipulando una sola banda, lo normal es que la imagen aparezca en pantalla en tonos de gris. Esto significa que cada ND tiene el mismo componente RVA. Un NV de 0, 0, 0, indica que el ND al que se aplique será visualizado como negro, mientras que 127, 127, 127, supone un gris medio y 255, 255, 255, blanco. Caso de que los tres valores sean distintos, se estará representando una imagen en color, ya sea con una o con tres bandas.

Por cuanto una CLUT implica una relación numérica entre ND y NV, ésta puede también representarse gráficamente en un diagrama bivariado, en donde el ND de la imagen se sitúa en el eje *X*, y el NV almacenado en la consola en el eje *Y*. Si se visualiza la imagen original, sin ningún realce, la CLUT puede describirse gráficamente como una línea recta, que pasa por el origen 0,0 y por el máximo 255, 255 (fig. 6.14*b*), lo que supone que el NV sea igual al ND. Con los procesos de expansión o compresión

FIG. 6.14. *Estructura tabular (a) y representación gráfica de una tabla de color (b)* (CLUT)

del contraste se modifica esa relación, de tal forma que los NV se distribuyan adecuadamente en el rango de la imagen.

La utilidad de estas tablas numéricas puede comprenderse fácilmente con un ejemplo. Supongamos que se pretende expandir el contraste en una imagen que presente un rango de ND entre 0 y 127. Para ajustar dicho rango al que permite el equipo de visualización (0 a 255) bastaría multiplicar por dos cada ND de entrada, lo que ampliaría su contraste a un rango entre 0 y 254. Ahora bien, tal opción conlleva dos problemas importantes: por un lado, transformar los ND iniciales para crear una nueva imagen de salida, lo que implica, o bien perder la información original, o bien aumentar las necesidades de almacenamiento; por otro lado, ese proceso supone un volumen de operaciones considerable: 786.432 multiplicaciones para una pequeña zona de 512 × 512 píxeles y tres bandas. Si consideramos que el realce es sólo una etapa intermedia, y normalmente efímera, del proceso, parece lógico buscar una alternativa a ese método. Gracias a la CLUT no es preciso transformar los ND para modificar el contraste visual de la imagen. Basta únicamente transformar la relación entre ND y NV que incluye la CLUT, de acuerdo al criterio que se estime más oportuno. En el ejemplo anterior, podría generarse una sencilla función donde NV = 2 ND, con lo que se obtendría el mismo efecto visual que la multiplicación de todos los ND, con un considerable ahorro de tiempo, pues la modificación de una CLUT sólo supone 768 cálculos (256 NV × 3 cañones de color), independientemente del tamaño de la imagen.

A continuación se presentan las técnicas más habituales en realce digital de imágenes. En pocas palabras, se trata de diversos procedimientos de obtener una CLUT apropiada a un fin específico: compresión o expansión del contraste, combinaciones en color multi-banda, visualización seudo-coloreada y construcción de tablas de color de significado temático.

5.1.2. *Compresión del contraste*

En caso de que el rango del sensor supere al número de niveles de gris que pueden visualizarse en pantalla, resulta preciso comprimir los ND originales, ajustando el rango de la imagen al permitido por el terminal gráfico. Estos ajustes son necesarios en dos casos: 1) cuando se cuenta con un sistema gráfico de reducida potencia, o 2) cuando se trabaja con un sensor de gran sensibilidad radiométrica.

La mayor parte de los equipos de visualización cuentan con una resolución en pantalla de 8 bits para cada uno de los tres cañones de color (rojo, verde y azul). Esto permite visualizar una banda en 256 niveles de gris, o tres en unos 16,8 millones de tonos de color (= 256^3). Hace algunos años, las tarjetas de bajo coste sólo disponían de un número mucho menor de colores (habitualmente 256 por píxel), lo que les impedía visualizar todo el rango de ND recogido originalmente por el sensor. Por esta razón, cuando se trabajaba con estos equipos resultaba necesario comprimir el contraste original de la imagen al número de NV disponibles. Asimismo, la compresión es precisa cuando se pretende visualizar una imagen AVHRR, codificada en 10 bits, Ikonos en 11 bits, o una del SAR (16 bits), sobre un monitor gráfico que sólo admite 8 bits. El problema puede solventarse de dos formas: eliminando una parte de la escala que no se considere relevante, o estableciendo una función de compresión de datos. La primera

solución es bastante obvia, aunque poco habitual, ya que supone una eliminación arbitraria de datos. La segunda puede abordarse por distintos criterios.

Lo más habitual es reducir el rango original de ND a un número conveniente de intervalos, de forma que la visualización en color resultante se asemeje en lo posible al color real. Esos intervalos suelen señalarse en función de las características de la distribución de los ND. Pueden indicarse intervalos de igual anchura, que contengan el mismo número de elementos, o que tengan unos márgenes delimitados por el intérprete. En cualquier caso, a cada uno de ellos se le asigna un único NV, eliminando su variación interna. Al reducirse el contraste de la escena, los colores se diferencian menos entre sí, reduciéndose la calidad de la visualización. No obstante, si la selección de colores es apropiada puede lograrse una visualización de bastante calidad. Para el caso de 3 bandas resulta habitual asignar 6 niveles a cada cañón de color, con lo que la composición contará con 216 tonalidades en pantalla (6^3). Existen otros algoritmos de compresión de imagen algo más refinados, que controlan el número de intervalos asignables a cada banda de la composición en color mediante un proceso similar a la clasificación no supervisada de la imagen, que luego veremos (Baudot, 1990; Muller, 1988*b*). Normalmente parten de establecer una serie de particiones en el espacio tri-dimensional formado por las tres bandas que forman una composición en color. En función de la anchura del histograma de cada banda se asignan más o menos particiones por color. Para asignar un intervalo de ND a cada una de esas particiones se establece el rango de variación más significativo en cada una de las bandas, calculado a partir de su media y desviación típica. Finalmente se clasifican los ND de la imagen en la partición más cercana en ese espacio. El resultado del proceso es una nueva imagen, mono-banda, que se asocia a una CLUT para representar, con la mayor semejanza posible, la variación cromática de la composición multi-banda, aunque sólo precisa la tercera parte de almacenamiento.

Actualmente, la mayor parte de los equipos cuentan con tarjetas gráficas de mucha mayor potencia, por lo que la compresión de imágenes no será una tarea vital, salvo por problemas de almacenamiento. En ese caso, es más común utilizar algoritmos de compresión del color, que consiguen una calidad apenas diferenciable de la original a una fracción de su tamaño. Son bien conocidos en la informática gráfica algunos algoritmos de compresión como el LZW, que permite crear imágenes GIF *(Graphics Interchange Format)*, muy utilizado en la edición de páginas web, aunque limitado a 256 colores, el JPEG *(Joint Photographic Expert's Group)*, que acepta hasta 24 bits por píxel y garantiza ratios de compresión de hasta 20:1 sin apreciable pérdida de calidad, y más recientemente el PNG *(Portable Network Graphics)*, desarrollado por Compuserve y W3C, que acepta también hasta 24 bits por píxel e incluso una capa adicional para superposiciones, aunque los ratios de compresión no son tan altos como los JPEG. Últimamente se han desarrollado nuevas técnicas para la compresión masiva de imágenes, de cara a su distribución a través de Internet. Entre ellas, están teniendo bastante aceptación las basadas en onditas *(wavelets)*, que consiguen índices de compresión bastante altos con baja pérdida de información.

5.1.3. *Expansión del contraste*

Más habituales que los procesos de compresión son las técnicas de realce del contraste, porque la mayor parte de las imágenes ofrecen un rango real de ND inferior a las capacidades del equipo de visualización. Aunque la resolución radiométrica de la mayor parte de los sensores actuales es de 8 bits por píxel, en la práctica ninguna imagen aprovecha todo ese rango, ya que difícilmente en una sola escena se encontrarán todos los posibles valores de radiancia para los que se calibró el sensor. De esta forma, el histograma real de los ND de cualquier imagen nunca satura los 256 posibles ND de la imagen. Visualmente esto implica que haya tonos de gris que no se utilicen, con lo que la imagen aparece en el monitor con poco contraste.

Por ejemplo, la figura 6.15*a* presenta la banda 3 de nuestra imagen de ejemplo, tal y como corresponde a sus ND originales. Como puede observarse, la imagen ofrece un bajo contraste, difuminándose algunas características de interés. Como ya vimos al analizar el histograma, esta banda presenta un rango de ND que ocupa sólo un pequeño sector de los 256 ND posibles, lo que confirma su reducido contraste.

De acuerdo a las ideas antes comentadas es posible realzar ese contraste, diseñando una CLUT que haga corresponder el rango de ND presente en la imagen con el total de los NV posibles. Varios procedimientos pueden conseguir este objetivo: 1) distribuir los NV linealmente, entre el máximo y mínimo ND de la imagen (fig. 6.15*b*),

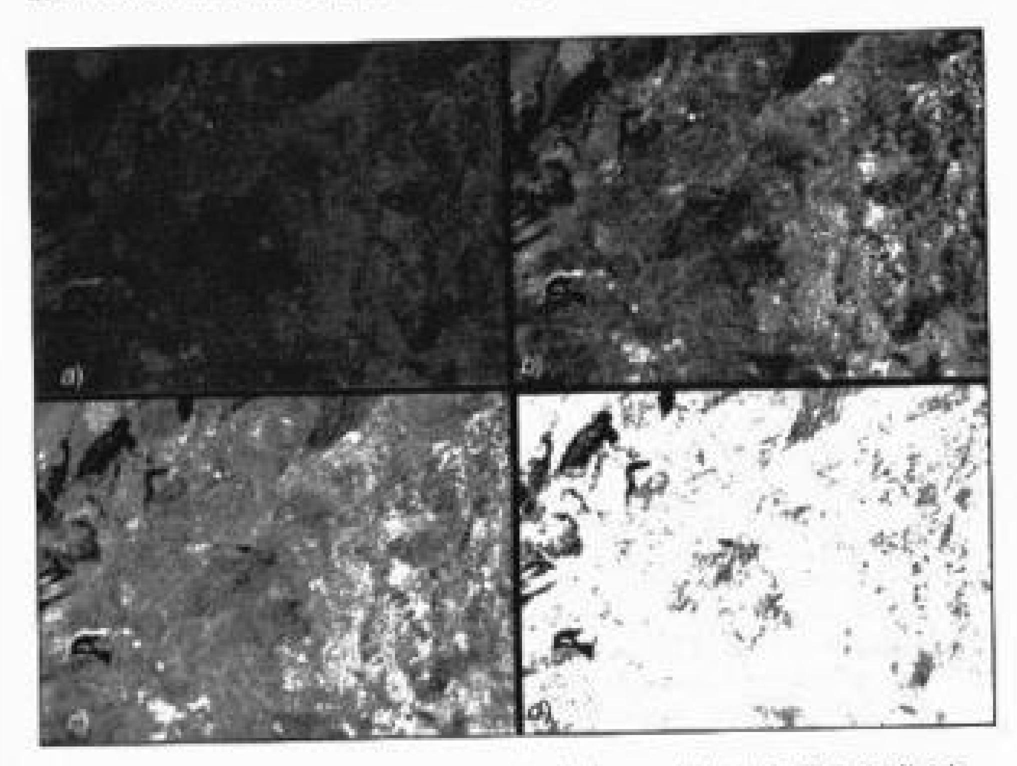


FIG. 6.15. *Diversos realces del contraste sobre la imagen: a) sin realce; b) realce lineal; c) realce frecuencial; d) realce especial sobre áreas de baja radiancia.*

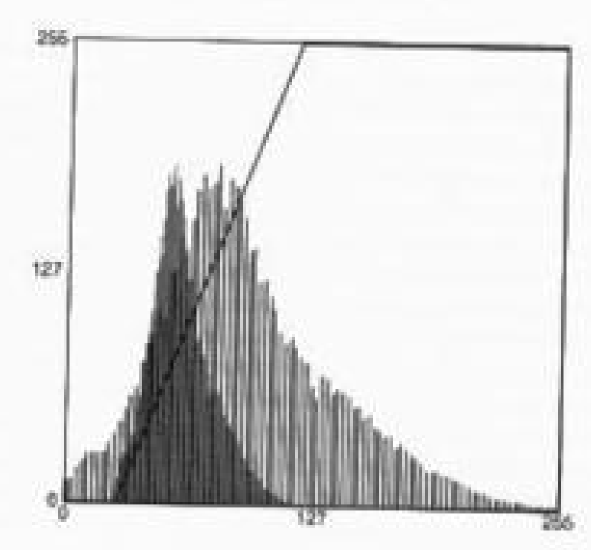


FIG. 6.16. *Expansión lineal del histograma y perfil de la CLUT. El histograma original aparece al fondo en gris.*

2) distribuir los NV a partir del histograma de los ND originales (fig. 6.15*c*), y 3) distribuir los NV en un determinado rango de interés (fig. 6.15*d*). Éstos son los tres procesos de expansión del contraste que a continuación se analizan. Para presentar estos realces consideraremos una CLUT de una sola columna. Si se pretende un realce para una composición en color se seguiría un modelo similar para expandir cada una de las bandas que la formen.

5.1.3.1. Expansión lineal

Es la forma más elemental de ajustar el contraste de la imagen al permitido por el equipo de visualización. Basta diseñar una CLUT en la que el ND mínimo y máximo de la imagen tengan asociados un NV de 0 y 255, respectivamente, distribuyendo linealmente el resto entre ambos márgenes. En la figura 6.15*b* aparece la imagen anteriormente presentada tras aplicarle una expansión lineal del contraste. Como puede observarse, la imagen aparece ahora más nítida, mejor contrastada. Su histograma ofrece una distribución más equilibrada (fig. 6.16). Las colas del histograma se han fijado en los extremos del rango y los valores intermedios están mejor repartidos en la escala. La representación gráfica de la CLUT supone una línea de mayor pendiente que la anterior, comprendida ahora entre los ND mínimo y máximo de la imagen.

Para llevar a efecto esta transformación se precisa encontrar una función lineal, que ajuste la relación ND-NV de acuerdo a la relación antes comentada. Esa función nos permite construir una CLUT apropiada, en la que se sustituya la correspondencia NV = ND, por una nueva, en donde los NV ocupen el rango completo de visualización y no sólo el que ofrece la imagen original. En definitiva, se trata de establecer una ecuación lineal del tipo siguiente:

$$NV = s + g\,ND \qquad [6.8]$$



en donde cada NV es una función de los ND originales, tras aplicarles dos constantes, denominadas sesgo *(bias)* y ganancia *(gain)*, respectivamente. Para conocer el valor de s y g basta aplicar un sencillo sistema de ecuaciones. Ya que sabemos que el mínimo y el máximo ND deben igualarse a 0 y 255, respectivamente, puede expresarse:

$$0 = s + g\,ND_{min}$$

y

$$255 = s + g\,ND_{max}$$

Sustituyendo en ambas fórmulas, los coeficientes se calculan como:

$$g = \frac{255}{ND_{max} - ND_{min}} \qquad [6.9]$$

y

$$s = \frac{-255 \cdot ND_{min}}{ND_{max} - ND_{min}} \qquad [6.10]$$

Aunque la transformación puede expresarse en un solo término como:

$$NV = \frac{ND - ND_{min}}{ND_{max} - ND_{min}} \cdot 255 \qquad [6.11]$$

pero resulta más apropiado utilizar [6.8], por ser la fórmula convencional en transformaciones lineales de datos. En lugar de igualar el ND_{max} y el ND_{min} a los valores máximo y mínimo, respectivamente, también pueden extraerse otros valores menos extremos, como los percentiles del 95 y 5 %, o un cierto número de desviaciones típicas por encima y por debajo de la media. Esto permitirá que tengan menos influencia posibles valores anómalos que presente la imagen.

Un ejemplo concreto puede ayudar a comprender mejor el proceso. Para obtener la expansión lineal del contraste antes presentada se partió de las medidas estadísticas de la banda 3 (tabla 6.1) que sirvieron para aplicar las fórmulas anteriores. En este caso se estableció un umbral mínimo y máximo a partir de la media ± dos desviaciones típicas. En consecuencia, el rango a expandir se situó entre 28 y 89 ND. De acuerdo a [6.9 y 6.10]:

$$g = 255 / (89\text{-}28) = 4{,}18$$

y

$$s = (-255 * 28) / (89\text{-}28) = -117{,}049$$

TABLA 6.2. *Expansión lineal de la imagen Torre100 (Media ± 2 S)*

ND	*NV*	*ND*	*NV*	*ND*	*NV*	*ND*	*NV*
0	0	65	154	130	255	195	255
5	0	70	175	135	255	200	255
10	0	75	196	140	255	205	255
15	0	80	217	145	255	210	255
20	0	85	238	150	255	215	255
25	0	90	255	155	255	220	255
30	8	95	255	160	255	225	255
35	29	100	255	165	255	230	255
40	50	105	255	170	255	235	255
45	71	110	255	175	255	240	255
50	91	115	255	180	255	245	255
55	112	120	255	185	255	250	255
60	133	125	255	190	255	255	255

Con estos valores puede construirse la CLUT que aparece en la tabla 6.2, de acuerdo a la siguiente expresión:

$$NV = ENT(-117{,}049 + 4{,}18\ ND)$$

la expresión ENT indica que el resultado se redondea al entero más cercano. Además, NV = 0 cuando NV < 0, y NV = 255 cuando NV > 255, puesto que la tabla de color sólo puede estar formada por números enteros entre 0 y 255. Esta tabla puede representarse gráficamente, de forma similar a cualquier recta de regresión (fig. 6.16).

5.1.3.2. Ecualización del histograma

La expansión lineal del contraste no tiene en cuenta la distribución de los ND en una imagen, sino sólo sus extremos. Parece lógico, sin embargo, tener en cuenta la distribución real de valores, aplicando una expansión proporcional a la frecuencia de aparición de cada uno de los ND. Esto implica generar una CLUT en la cual cada NV tenga, aproximadamente, el mismo número de ND de la imagen. En otras palabras, aquellos ND con mayor número de píxeles serán los que, proporcionalmente, ocupen un mayor rango de visualización en el monitor. El proceso es más laborioso que el comentado previamente, pero ofrece mejores resultados, especialmente si la imagen original presenta una distribución gausiana.

Como puede observarse en la figura 6.15*c*, la ecualización del histograma ha supuesto un realce más equilibrado, mostrando menos contraste entre las zonas de alta reflectividad y las de baja. A consecuencia de este realce, el histograma de la imagen ofrece una mejor distribución de los datos (fig. 6.17). También se evidencia que el perfil gráfico de la CLUT no es recto sino curvilíneo, similar al que tendría el histograma acumulado de los ND originales.

La lógica de cálculo pasa por igualar el histograma de los NV con el de los ND. Para construir una CLUT con un trazado similar al histograma de la imagen puede seguirse el proceso de la tabla 6.3.

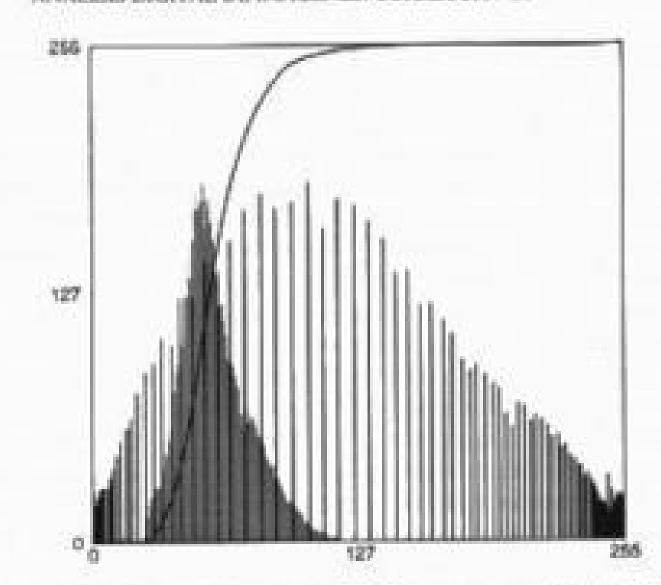


FIG. 6.17. *Expansión frecuencial del histograma y perfil de la CLUT.*

1. Calcular la frecuencia absoluta y acumulada de los ND de la imagen original.
2. Esta frecuencia se compara con una frecuencia objeto, que sería la que se obtendría si todos los NV de la imagen tuvieran la misma frecuencia (el cociente entre el total de píxeles de la imagen y el número de NV posibles). En nuestro caso, la frecuencia objeto sería 736.136 / 256; esto es, 2875,53 píxeles por cada NV. Trabajando con frecuencias relativas, cada NV debería albergar el 0,3906 % de los píxeles de la imagen. Estos valores también se acumulan para compararlos con la frecuencia acumulada de los ND de la imagen.
3. De esta comparación se selecciona, para cada ND, el NV que presente un valor más próximo en la frecuencia objeto acumulada.

En la tabla 6.3 se incluye un resumen de los cálculos necesarios para obtener una tabla de color con expansión frecuencial. Para simplificar las cosas hemos seleccionado únicamente rangos de 5 ND. En consecuencia, cada intervalo en la frecuencia objeto debería presentar 1,95 % de los píxeles de la imagen. Como observamos en esta tabla, el NV correspondiente a todos los ND inferiores a 25 es 0, porque su frecuencia objeto más similar es la correspondiente al NV = 0 (la frecuencia acumulada de la imagen en todo ese rango es 0,056 y la frecuencia objeto acumulada es 1,95). De la misma forma, al ND = 40 le corresponde el NV = 30, porque su frecuencia acumulada (12,993) es más similar a la del NV = 30 (13,672), y así sucesivamente hasta culminar el proceso.

5.1.3.3. Expansión especial del contraste

Supone un caso particular de los métodos anteriormente estudiados. La novedad radica en restringir el contraste a un rango específico de ND, en donde se manifieste con mayor claridad una cubierta de interés. Por ejemplo, en una aplicación sobre zonas

Con la creciente proliferación de los sensores hiperespectrales, las posibilidades de realizar composiciones coloreadas de bandas son prácticamente ilimitadas. Lógicamente, sólo algunas tendrán un interés específico para una determinada aplicación, y muchas de ellas serán casi idénticas. De cara a establecer algún criterio más objetivo para seleccionar las bandas más adecuadas para una composición en color se han propuesto algunos índices estadísticos y cromáticos, que permiten retener mejor la varianza original de los datos. De esta forma se define el denominado «Índice óptimo» (*Optimum Index Factor*, OIF):

$$OIF = \frac{\sum_{k=1,3} s_k}{\sum_{j=1,3} |r_j|} \qquad [6.12]$$

donde s_k indica la desviación típica de cada una de las tres bandas que intervienen en la composición y r_j el coeficiente de correlación entre cada par de esas mismas bandas (Jensen, 1996, pp. 97-100).

Otros métodos propuestos para seleccionar la composición en color idónea tienen en cuenta el elipsoide de máxima variación, que supone un planteamiento novedoso frente a los métodos estadísticos convencionales (Sheffield, 1985) y el valor de la divergencia (Mather, 1998), que luego comentaremos (cap. 7, apdo. 2). Los resultados de estas técnicas muestran una tendencia similar. Para las imágenes TM, con las que se han aplicado profusamente estos índices, la mayor parte selecciona una banda en el VIS, otra en el IRC y otra en el SWIR, identificando así los tres ejes principales de variación en una imagen TM (excluido el térmico).

5.3. Empleo del seudo-color

Varios autores han puesto en evidencia que el ojo humano es más capaz de distinguir tonos de color que intensidades de brillo (Ruiz, 1994). Por tanto, el empleo del color puede ayudar a la interpretación de una imagen, incluso si sólo disponemos de una banda. En estos casos, no podemos hablar propiamente de color, pues se requerirían tres bandas, sino más bien de seudo-color. Para una mezcla de tres bandas utilizamos distintos NV en cada cañón de color (R,V,A), siendo iguales cuando se visualiza una sola banda (en blanco y negro). Sin embargo, podemos diseñar también una CLUT en donde se varíen los NV para los tres colores, aunque sólo haya una banda de ND de entrada. En otras palabras, el seudo-color implica crear una CLUT que asocie el ND de una sola banda a distintos componentes de rojo, verde y azul. Esto puede tener sentido en dos casos: 1) cuando se pretenda obtener una clave de color en una imagen clasificada, y 2) cuando se intente realzar el análisis de una determinada banda de la imagen, sustituyendo los niveles de gris por tonos de color. También se utiliza el seudo-color cuando se comprime una imagen en color de 24 a 8 bits, generándose una paleta de color que se asimile a la variedad cromática original contenida en la composición de las tres bandas de entrada.

A modo de ejemplo, aparece en la tabla 6.4 una CLUT diseñada para representar visualmente una imagen clasificada. En ella, cada ND indica una clase temática distinta (por ejemplo, una categoría de ocupación del suelo), que será visualizada en pantalla con distintos tonos de color. El ND 1 (supongamos que indique zonas urbanas) se visualizará en color rojo, ya que aplicamos la intensidad máxima de rojo (recordemos que la escala comprende de 0 a 255) y una mínima de verde y azul. De la misma forma, el ND 2, que podría representar cubierta vegetal, se visualizaría en verde, dando un valor máximo a este cañón de color y mínimo a los otros dos. Lógicamente, se pueden plantear colores por mezcla de distintas intensidades de R,V,A. Por ejemplo, el ocre indica una máxima intensidad de rojo y media de verde, sin azul. La paleta de color disponible permite visualizar, por tanto, combinaciones de 256 niveles RVA, o lo que es lo mismo unas 16,8 millones de tonalidades (256^3). Lógicamente, no todos estos colores pueden distinguirse en la práctica, por lo que bastará con seleccionar unos cuantos (entre 10 y 20 suele ser necesario) para construir una clave de color apropiada a cualquier clasificación temática.

Tabla 6.4. *Ejemplo de CLUT para una imagen clasificada*

ND	*NV Rojo*	*NV Verde*	*NV Azul*	*Color resultante*
0	0	0	0	Negro
1	255	0	0	Rojo
2	0	255	0	Verde
3	0	0	255	Azul
4	0	255	255	Cian
5	255	255	0	Amarillo
6	255	127	0	Ocre
7	127	127	127	Gris
8	255	0	127	Rosa

También puede emplearse el seudo-color para visualizar en color alguna de las bandas originales, realzando el análisis de esa banda. El seudo-color puede aplicarse al conjunto de los ND de la escena, diseñando una CLUT formada, por ejemplo, por números aleatorios entre 0 y 255, para cada uno de los tres colores. Ahora bien, esto complicará la interpretación, pues no habrá ninguna escala de referencia para el analista. Por ello, lo más habitual es aplicar una transformación del color progresiva, en donde la CLUT tiene una dirección determinada de gradación: por ejemplo, desde los tonos azules para los ND bajos hasta los rojos, para los más altos. Una aplicación concreta de esta técnica sería la visualización de imágenes de temperaturas (6.2.4) o de índices de vegetación (cap. 7, apdo. 1.2), que tratan de representar la intensidad de dos fenómenos físicos (calentamiento y vigor vegetal, respectivamente), y pueden representarse, por ejemplo, por tonos de azul-rojo, en el primer caso, y de ocre-verde, en el segundo.

En estos casos, en lugar de aplicar una CLUT a toda la escala de ND original, puede ser recomendable dividir antes el rango original en una serie de intervalos de densidad *(density slicing)*. Este nombre se emplea para indicar que cada uno de esos grupos corresponde a valores de radiancia relativamente similares. Esto facilita la posterior interpretación visual de los resultados, ya que el observador podrá distinguir con mayor claridad entre diversas categorías. Los umbrales que definen cada intervalo pueden establecerse arbitrariamente o con algún criterio estadístico: por ejemplo, señalando una anchura constante a partir del rango, o seleccionando intervalos de la misma frecuencia. En cualquier caso, los umbrales elegidos pueden modificarse interacti-

vamente, con lo que el usuario puede detectar, en cada banda, el rango de ND que comprende un fenómeno de interés. Asimismo, le facilita un primer balance de los solapes con otras categorías, de cara a su clasificación digital.

5.4. Filtrajes

5.4.1. *Naturaleza de un filtro digital*

Al igual que en las técnicas fotográficas convencionales, el filtro se aplica en análisis digital para aislar componentes de interés. Hemos visto previamente técnicas que mejoran el contraste tonal en la imagen, esto es, la diferencia entre los valores más oscuros y más claros que se visualizan en el monitor. El otro componente de la imagen es el contraste espacial, o si se prefiere la diferencia entre el ND de un determinado píxel y el de sus vecinos. Mediante técnicas de filtraje se pretende suavizar o reforzar estos contrastes espaciales, de tal forma que los ND de la imagen se asemejen o diferencien más de los correspondientes a los píxeles que les rodean.

Como ya vimos anteriormente, si trazamos un perfil radiométrico en una determinada zona de la imagen (fig. 6.13) observamos numerosos picos y valles, a consecuencia de cambios bruscos en las características radiométricas de la cubierta del suelo. Como en cualquier serie estadística, esa línea podría considerarse como una suma de dos componentes: las bajas frecuencias, que indicarían la tendencia general de la variación, y las altas frecuencias, que señalarían los contrastes más locales. El propósito de los filtros digitales es retener unas u otras, en función del objetivo que persiga el intérprete. Se denominan, respectivamente, filtros de paso bajo y paso alto. Hay dos procedimientos para llevarlos a cabo: aplicar a todos los píxeles de la imagen una operación aritmética que tenga en cuenta el valor de los inmediatos (filtros en el dominio espacial), o retener ciertos componentes de las frecuencias de la imagen (filtros en el dominio de la frecuencia). Los primeros resultan bastante sencillos de comprender y aplicar, mientras los segundos requieren un aparato matemático que excede el contenido de este manual. Baste aquí decir que se basan en las transformadas de Fourier, que convierte una imagen en una función bidimensional con dos componentes de frecuencia (horizontal y vertical), asumiendo que la variación de los ND en la imagen puede aproximarse a una función continua compleja. Aplicada la transformación, se obtienen los espectros de Fourier, que representan los componentes de fase y amplitud que definen una determinada imagen. Sobre ese espectro pueden aplicarse ciertos filtros y correcciones, especialmente valiosas cuando se trata de ruidos sistemáticos (por ejemplo un bandeado), pues aparecerán en una determinada dirección de la frecuencia (Pinilla *et al.*, 1997; Richards, 1993). Una vez realizada la modificación puede retornarse al dominio de la imagen aplicando una transformada de Fourier inversa.

Hemos incluido los filtros digitales en este capítulo porque las técnicas de filtraje se dirigen, directamente, al realce visual de la imagen. Al igual que las operaciones antes comentadas, pretenden mejorar la visualización de las imágenes, ya sea para eliminar valores anómalos, ya para resaltar rasgos lineales de interés. Sin embargo, a diferencia de las operaciones ya comentadas, el filtraje implica modificar los ND originales, y no sólo la forma en que se representan visualmente. En otras palabras, no se trata

sólo de transformar los NV almacenados en las CLUT, sino también los ND de la imagen (aunque habitualmente se realice en memoria gráfica, para no perder los datos originales). Por tanto, si pretende abordarse una clasificación digital, las imágenes filtradas no resultan, en principio, muy convenientes, aunque refuercen visualmente rasgos de interés respecto a la imagen original.

Como hemos indicado, se suelen distinguir dos tipos de filtros de acuerdo al objetivo que se persiga: los filtros de paso bajo *(low pass filtering)* tienden a destacar el componente de homogeneidad en la imagen, subrayando aquellas áreas donde la frecuencia de cambio es baja, mientras los filtros de paso alto *(high pass filtering)* se dirigen a realzar los componentes de alta frecuencia: esto es, aquellas áreas de alta variabilidad, donde el contraste espacial es intenso.

Ambos tipos de filtrado pueden abordarse con el mismo método. Si el objetivo último es poner a los píxeles de la imagen en relación con sus vecinos (ya sea para homogeneizarlos, ya para diferenciarlos), basta realizar una serie de operaciones aritméticas entre cada uno de ellos y sus inmediatos. La forma concreta de efectuar este proceso es aplicar sobre los ND originales una matriz móvil de coeficientes de filtraje (CF). Esta matriz (denominada, por algunos autores, *kernel*) puede tener un tamaño variable, en función del número de píxeles vecinos que queramos implicar en el proceso. Lo habitual es que se trate de una matriz de 3 × 3 CF, que se aplica sucesivamente a todos los píxeles de la imagen. Puede también disponerse de matrices de filtraje mayores, de 5 × 5 o 7 × 7 píxeles. Cuanto mayor sea ésta, el efecto de suavizado o realce espacial es más intenso, al considerar como vecinos un mayor número de píxeles.

En cualquier caso, la matriz de CF se aplica sucesivamente a la imagen original, desplazándose hacia la derecha tras calcular el nuevo valor del píxel central, que es el único que se modifica en cada desplazamiento (fig. 6.18). El siguiente cálculo, sin embargo, se obtiene de los ND originales, y no de los ND ya filtrados, con objeto de que toda la imagen tenga la misma función de filtrado.

El resultado de un filtro digital depende de los CF señalados por el usuario. Si éstos tienden a ponderar el valor central en detrimento de los circundantes, el píxel refuerza sus diferencias frente a los vecinos. Por el contrario, si los coeficientes favorecen a los píxeles periféricos, el central se asemejará más a los adyacentes. Es obvio decir que en el primer caso nos encontraríamos ante un filtro de paso alto, mientras en el segundo sería de paso bajo.

En suma, el procedimiento matemático del filtraje consiste en relacionar cada píxel con sus vecinos, de acuerdo a unos coeficientes determinados por el usuario. En el caso de una matriz de 3 × 3 CF, la fórmula para obtener el ND filtrado sería (Mather, 1998):

$$ND'_{i,j} = \frac{\sum_{p=-1,1} \sum_{q=-1,1} ND_{i+p,j+q} CF_{f+p,c+q}}{\sum_{p=-1,1} \sum_{q=-1,1} CF_{f+p,c+q}} \qquad [6.13]$$

donde $ND_{i,j}$ indica el ND original del píxel *i, j*; $ND'_{i,j}$, el ND de salida para ese mismo píxel; CF, el coeficiente de filtraje correspondiente, y *f* y *c* la fila y columna central de la matriz de filtraje. El resultado de esta fórmula se aproxima al entero más cercano. También se ha propuesto dividir el numerador por el número de píxeles de la ventana de filtrado (9 si se trata de 3 × 3), independientemente de los CF que se señalen.

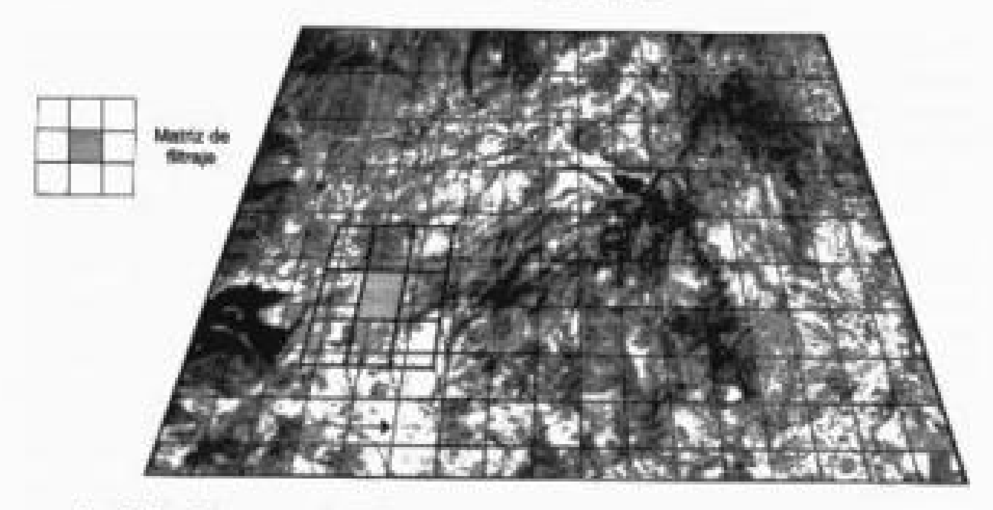


FIG. 6.18. *Diagrama sobre el funcionamiento de un filtro espacial. En cada momento se aplica la operación sobre el píxel central (en gris) de la matriz de filtraje.*

El proceso abordado en un filtraje puede ilustrarse con un sencillo ejemplo. Se pretende aplicar un filtro de paso bajo a una pequeña imagen de 5 × 6 píxeles, empleando la fórmula anterior sobre una matriz de 3 × 3 CF (fig. 6.19). La observación del resultado permite extraer algunas consideraciones de interés. En primer lugar, se constata que el área filtrada se limita a los píxeles centrales. Los píxeles de borde no se afectan por el proceso, puesto que no tienen los 8 vecinos necesarios para realizar el cálculo. Esta característica es común a cualquier filtraje, ya sea de paso alto o bajo. Obviamente, en el caso de una imagen de mayor tamaño (512 × 512 píxeles, por ejemplo), la pérdida de esos píxeles de borde no supone una grave inconveniencia.[4] Otros autores prefieren aplicar algún promedio especial a estos píxeles, en lugar de igualarlos a cero.

12	14	17	24	32	34
10	18	21	35	38	40
25	15	17	27	40	43
18	16	18	24	29	39
14	16	20	20	27	36

Imagen original

1	1	1
1	2	1
1	1	1

0	0	0	0	0	0
0	17	21	29	35	0
0	17	21	28	35	0
0	18	19	25	31	0
0	0	0	0	0	0

Imagen filtrada

FIG. 6.19. *Ejemplo de filtraje digital.*

4. En una matriz de filtraje de 3 × 3 se pierden la primera y última fila y columna. Si empleamos matrices de mayor tamaño, la merma será más significativa: con 5 × 5 se perderían las dos primeras y últimas; con 7 × 7 las tres, etc

Volviendo a nuestro ejemplo, el nuevo ND del píxel central se calcula por un promedio de los 8 vecinos, con una pequeña ponderación del valor central. Esos coeficientes se han aplicado a todos los píxeles centrales de la imagen. Por ejemplo, el situado en la fila 3, columna 3, con un ND inicial de 17 se convierte en la nueva imagen en:

$$ND'3,3 = (18 + 21 + 35 + 15 + 2 \times 17 + 27 + 16 + 18 + 24) / 10 = 20,8 \approx 21$$

que es un valor más cercano al sector oriental de la imagen, con valores bajos. De igual forma se procede con el resto de los píxeles hasta obtener la imagen filtrada. Al terminar el proceso, el contraste global se ha reducido: mientras la desviación típica original de los 12 píxeles afectados por el filtraje es 8,91, la correspondiente a los filtrados es 6,77, lo que indica una mayor homogeneidad espacial en la nueva imagen. Un efecto más claro se hubiera obtenido al analizar una mayor superficie y/o aplicar un promedio simple en la matriz de CF. Un proceso similar se emplearía para cualquier otro tipo de filtraje.

5.4.2. *Filtros de paso bajo*

Tienen por objetivo suavizar los contrastes espaciales presentes en la imagen. En breves palabras, se trata de asemejar el ND de cada píxel al de los píxeles vecinos, reduciendo la variabilidad espacial de la escena. En términos visuales, esto supone que la imagen filtrada ofrece perfiles menos nítidos, más difuminados, como puede apreciarse en la figura 6.20, que recoge la banda 4 original y filtrada de la imagen que venimos comentando. Si comparamos ambos sectores de esta figura se observa nítidamente el efecto del filtraje. Como vemos, la imagen filtrada se muestra bastante difuminada, se han perdido la mayor parte de los contrastes espaciales, especialmente en lo que se refiere a la red vial de las áreas residenciales (A en la figura 6.20). El efecto es más evidente cuanto mayor es el tamaño de la ventana de filtraje. A cambio, la diferencia en la señal radiométrica entre estas zonas y las no urbanizadas se habrá hecho más patente, al eliminarse gran parte del contraste interno.

Este tipo de filtraje se utiliza para restaurar los errores aleatorios que pueden presentarse en los ND de la imagen, fruto de un defecto en la adquisición o recepción de los datos. Así mismo, se ha empleado para reducir la variabilidad espacial de algunas

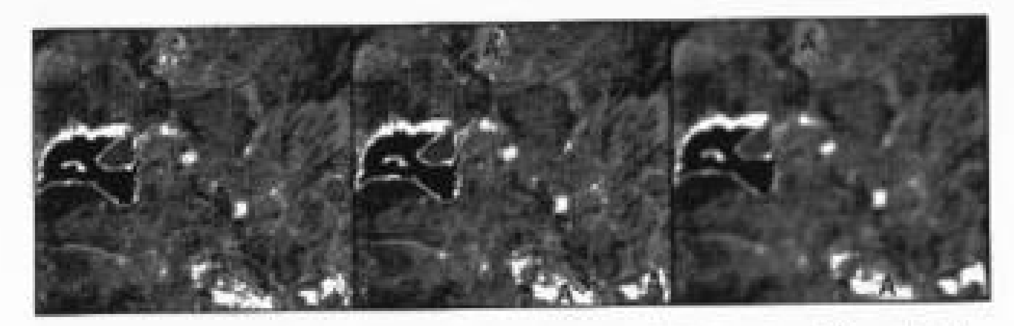


FIG. 6.20. *Filtros de paso bajo sobre una ventana de Torrel00: de izqda. a dcha.: original, filtro de 3 × 3, filtro de 9 × 9.*

categorías, como paso previo a la clasificación. En este caso se pretende atenuar el denominado «ruido de la escena», producido en las zonas altamente heterogéneas en relación con la resolución espacial del sensor. El caso más claro, y el más estudiado, es el que se produce en las zonas urbanas, en donde se mezclan distintos tipos de cubierta en un reducido espacio. Para disminuir esta variabilidad espacial se han propuesto diversos filtros de paso bajo, que tienden a homogeneizar los ND de esas zonas. El efecto de estos filtros se ha mostrado bastante eficiente de cara a la clasificación digital (Cushnie y Atkinson, 1985; Haack *et al.*, 1987). También el filtro de paso bajo puede utilizarse para obtener la «señal de fondo» cuando intentemos comparar un ND con su contexto, de cara a la detección de algún rasgo de interés que sea especialmente anómalo en su entorno, como ocurre con los fuegos activos (Flasse y Ceccato, 1996) o las nubes (Saunders y Kriebel, 1988), o para obtener la reflectividad característica de una zona de cara a corregir el efecto de adyacencia (Richter, 1997).

El filtro de paso bajo puede obtenerse a partir de diversas matrices de filtraje. Algunas de las más habituales son:

1)

1,00	1,00	1,00
1,00	1,00	1,00
1,00	1,00	1,00

2)

1,00	1,00	1,00
1,00	2,00	1,00
1,00	1,00	1,00

3)

0,25	0,50	0,25
0,50	1,00	0,50
0,25	0,50	0,25

La primera es un simple promedio de los 9 píxeles que componen la ventana de filtraje, mientras las dos siguientes ponderan un poco el valor central para evitar una excesiva pérdida de detalle.

En los últimos años se ha aplicado con buen rendimiento otro tipo de filtraje, basado sobre la mediana en lugar de la media. El filtro mediano consiste en sustituir el ND del píxel central por la mediana de los ND correspondientes a los píxeles vecinos. Su interés se corresponde con el propio de la mediana como medida de centralidad, ya que es menos sensible a los valores extremos y entraña una menor modificación de los datos que la media aritmética; de ahí que se haya recomendado su empleo dentro de las técnicas de análisis exploratorio de datos (Shaw y Wheeler, 1985). En el contexto del ADI se ha empleado para eliminar valores anómalos aislados, fruto de ruidos aleatorios en la adquisición de los datos. Preserva mejor los contornos que el filtro promedio, pero demanda un mayor volumen de cálculo. Se ha aplicado con éxito para reducir el moteado brillante *(speckle)* de las imágenes radar (Blom y Daily, 1982).

5.4.3. *Filtros de paso alto*

Este tipo de filtros pretende aislar los componentes de alta frecuencia en una imagen. En términos espaciales, esto supone remarcar digitalmente los contrastes espaciales entre píxeles vecinos, enfatizando los rasgos lineales presentes en la imagen, como carreteras, parcelas o accidentes geológicos. En definitiva, se intenta reforzar los contornos entre áreas homogéneas, evidenciando cualquier discontinuidad.

Varios métodos pueden conseguir este objetivo. El más sencillo pasa por restar de la imagen original la obtenida por un filtro de paso bajo. La razón es bastante obvia: si lo que se pretende es aislar los componentes de alta frecuencia (alta variabilidad), basta restar de la imagen original aquellos correspondientes a la baja frecuencia, con lo que sólo quedarían los requeridos, que se añadirían a la imagen original. En suma:

$$ND'_{i,j,s} = ND_{i,j} + (ND_{i,j} - ND_{L,i,j}) \qquad [6.14]$$

donde ND' corresponde al ND de salida, ND al original, y ND_L al resultado de un filtro de paso bajo.

Más común es, sin embargo, emplear matrices de filtraje, similares a las anteriormente analizadas. En este caso, los CF se disponen de tal modo que se refuerza el contraste entre el píxel central y los vecinos. Dos matrices frecuentemente utilizadas son:

4)

−1	−1	−1
−1	9	−1
−1	−1	−1

5)

0	−1	0
−1	4	−1
0	−1	0

ambas se derivan del análisis de gradientes de cambio en la imagen. El segundo filtro, denominado Laplaciano, se recomienda para el realce de rasgos lineales en la ciudad (Jensen, 1996).

Puede analizarse la aplicación de este filtro sobre la imagen Torrel00 en la figura 6.21. El proceso implica un mayor realce de los abundantes rasgos lineales de la imagen: carreteras y líneas de ferrocarril, viario urbano, etc., que aparecen con color claro, quedando las áreas homogéneas en oscuro. Puede abordarse un filtro menos severo incrementando el valor del píxel central, lo que permitirá conservar mejor la radiometría original de la imagen.

Para reforzar aún más las fronteras entre categorías puede ser recomendable aplicar filtros no lineales, que se dirigen a realzar los gradientes de cambio en la imagen. Uno de los más empleados es el denominado detector de bordes de Sobel (González y Wintz, 1977), que realza la variación entre filas y columnas de la matriz de filtraje. En una ventana de 3 × 3 píxeles, el ND del píxel central se calcula de la forma siguiente:

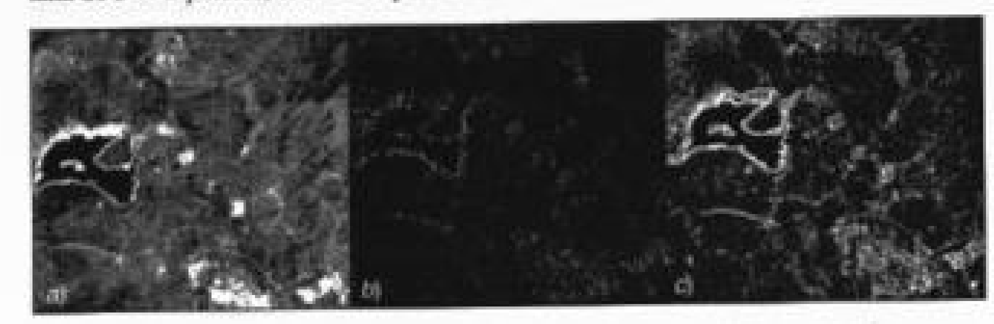


FIG. 6.21. *Filtros de paso alto sobre una ventana de Torrel00: a) original, b) filtro laplaciano de 3 × 3, c) filtro de Sobel.*

$$\mathrm{ND}'_{i,j} = \sqrt{C^2 + F^2} \qquad [6.15]$$

donde:

$$C = (\mathrm{ND}_{i-1,j+1} + 2\,\mathrm{ND}_{i,j+1} + \mathrm{ND}_{i+1,j+1}) - (\mathrm{ND}_{i-1,j-1} + 2\,\mathrm{ND}_{i,j-1} + \mathrm{ND}_{i+1,j+1})$$

y

$$F = (\mathrm{ND}_{i-1,j-1} + 2\,\mathrm{ND}_{i-1,j} + \mathrm{ND}_{i-1,j+1}) - (\mathrm{ND}_{i+1,j-1} + 2\,\mathrm{ND}_{i+1,j} + \mathrm{ND}_{i+1,j+1})$$

El efecto de este filtro sobre nuestra imagen puede observarse en la figura 6.21*c*. Se remarcan con claridad las principales vías de comunicación, los límites del embalse y de los núcleos residenciales, mientras quedan en tonos oscuros únicamente los sectores de mayor homogeneidad. El resultado parece algo más rígido que el filtro laplaciano, pero recoge mejor los gradientes de cambio en este sector de la imagen.

Además de los filtros arriba expuestos, una forma sencilla de realzar los bordes sería realizar una copia de la imagen, desplazarla una fila y/o columna sobre la original y restar ambas. Aquellos píxeles que ofrezcan un valor cercano a 0 indicarán áreas de escasa variación, mientras cuanto mayor sea esta diferencia, mayor será también el contraste especial entre píxeles vecinos. Asimismo puede definirse una dirección de contraste, hacia valores superiores o inferiores según sea negativa o positiva la diferencia. Se han desarrollado otros métodos de realce de bordes para aplicaciones específicas, como son la detección de lineamientos (Moore y Waltz, 1983), el realce de plumas de agua (Jensen, 1996, pp. 162-165), o la delimitación de calles en una ciudad (Gong y Howarth, 1990*a*).

Las matrices de filtraje antes comentadas permiten subrayar cualquier rasgo fronterizo de la imagen, independientemente de su orientación. La misma técnica puede emplearse para construir filtros direccionales, con el propósito de reforzar aquellas líneas que sigan determinadas orientaciones. Basta disponer adecuadamente los CF, distribuyéndolos en sectores de la matriz. Algunos ejemplos de matrices de filtraje para conseguir este análisis direccional son:

6) Norte

1	1	1
1	−2	1
−1	−1	−1

7) Sur

−1	−1	−1
1	−2	1
1	1	1

8) Este

−1	1	1
−1	−2	1
−1	1	1

9) Oeste

1	1	−1
1	−2	−1
1	1	−1

10) Sureste

−1	−1	−1
−1	−2	1
−1	−1	1

11) Noreste

1	1	1
1	−2	−1
1	−1	−1

12) Suroeste

1	−1	−1
1	−2	−1
1	1	1

13) Noroeste

1	1	1
−1	−2	1
−1	−1	1



FIG. 6.22. *Filtros direccionales: a) original; b) filtro este; c) filtro norte; d) filtro sureste.*

Conviene indicar que el nombre de estas matrices es consecuencia de la dirección del contraste que señalan, y no de la dirección que están realmente realzando, que es precisamente la perpendicular. Por ejemplo, la matriz norte estaría reforzando líneas situadas este-oeste (en concreto la frontera norte de esas líneas), mientras la este refuerza el borde oriental de las líneas norte-sur.

La figura 6.22 recoge la aplicación de estos filtros direccionales al mismo sector de la imagen que venimos comentando. Son patentes las diferencias entre las tres direcciones que estamos realzando (especialmente claro el contraste entre el filtro norte y el este), lo que permite analizar patrones direccionales referidos a vías de comunicación o rasgos geológicos de interés. Un ejemplo similar del interés de este tipo de filtros podemos observarlo sobre la fig. 6.23, que incluye un sector del centro urbano de la ciudad de Madrid (imagen Madrid92). El lector podrá comprobar por sí mismo la influencia de las distintas matrices de filtraje sobre la imagen, reforzando las calles que siguen la principal dirección del borde realzado.

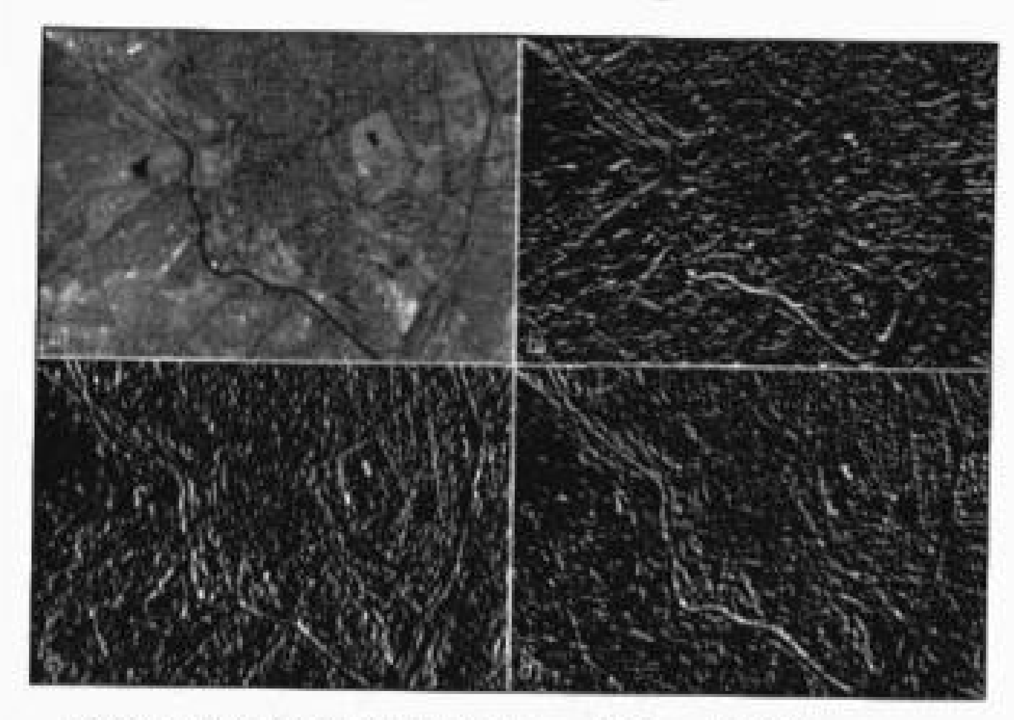


FIG. 6.23. *Filtros direccionales sobre una ventana de la imagen Madrid92: a) original; b) filtro norte; c) filtro oeste; d) filtro noreste.*

6. Correcciones de la imagen

Con este nombre se indican aquellos procesos que tienden a eliminar cualquier anomalía detectada en la imagen, ya sea en su localización, ya en la radiometría de los píxeles que la componen. Estas operaciones tienden a disponer los datos en la forma más cercana posible a una adquisición idónea, por ejemplo, situándolos sobre su posición geográfica correcta (georreferenciación), o reconstruyendo la radiancia detectada por el sensor a partir de los ND de la imagen. No obstante, el término corrección, que da título a este epígrafe, conviene manejarlo con ciertos matices, puesto que no todas las operaciones aquí incluidas pueden calificarse propiamente como soluciones a defectos de adquisición de los datos. De hecho, la georreferenciación cartográfica de la imagen implica introducir una nueva deformación, ya que no es posible representar coordenadas geográficas (latitud, longitud) sobre un plano con total exactitud. Sin embargo, esta operación es necesaria si se quiere que los resultados del análisis tengan validez cartográfica o puedan conectarse con otros datos auxiliares almacenados en un SIG.

Hemos incluido en este epígrafe dos grandes temas, las correcciones de la radiometría de la imagen (transformaciones de los ND para solventar los problemas de adquisición), y las correcciones geométricas (georreferenciación). Comentaremos antes las principales fuentes de error que puede implicar la captura de la imagen.

6.1. Fuentes de error en una imagen espacial

Cualquier imagen adquirida por un sensor remoto, ya sea aéreo o espacial, presenta una serie de alteraciones radiométricas y geométricas debidas a muy variados factores. Esto explica que la imagen finalmente detectada no coincida exactamente con la radiancia-posición-forma-tamaño de los objetos que incluye. En el caso concreto de las imágenes espaciales, las deformaciones más frecuentes pueden agruparse en cuatro apartados (Bernstein, 1978; Mather, 1998):

1. Distorsiones originadas por la plataforma. Pese a la gran estabilidad de un satélite de observación, muy superior a la que ofrece un avión, pueden producirse pequeñas variaciones en la altitud de su órbita, en la velocidad, o en la orientación de cualquiera de sus tres ejes: alabeo *(roll)*, cabeceo *(pitch)*, giro lateral *(yaw)*. En el primer caso se producen cambios en la escala de la imagen, mientras, en el segundo, distorsiones de distinto tipo en su geometría de adquisición (fig. 6.24). Ambos factores pueden considerarse como no sistemáticos, puesto que aparecen de forma esporádica y son, por ello, difícilmente predecibles y complejos de modelar (Welch y Usery, 1984).

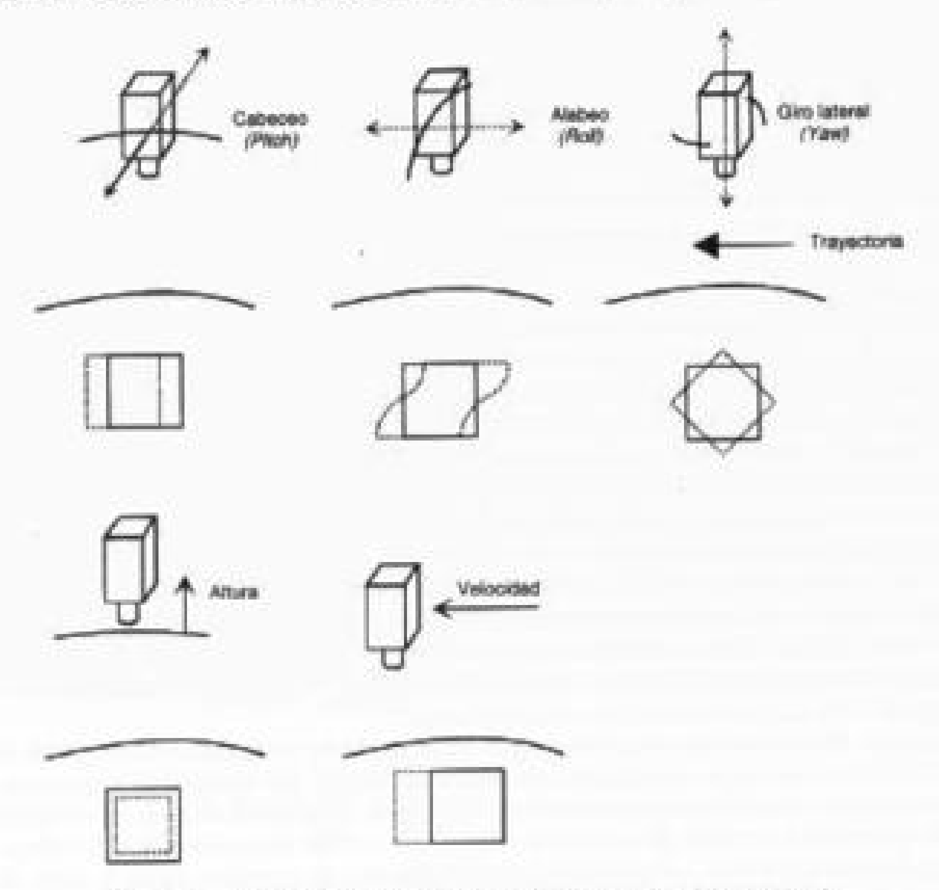


FIG. 6.24. *Algunas fuentes de error geométrico en una imagen espacial.*

2. Distorsiones provocadas por la rotación terrestre. Teniendo en cuenta la altitud orbital y el área abarcada por el sensor, el efecto de rotación de la tierra puede aparecer claramente en la imagen. Por ejemplo, en el caso del MSS del satélite Landsat, cada imagen de 185 × 185 km se adquiría, en nuestras latitudes, en unos 28 segundos. En este lapso de tiempo, desde la primera a la última línea de barrido, la Tierra se desplaza sensiblemente (unos 8 km), lo que causa, junto a la propia inclinación de la órbita, una orientación de la imagen noreste-suroeste. También provocada por la superficie terrestre es la variación del tamaño del píxel por efecto de la curvatura terrestre.

3. Distorsiones provocadas por el sensor. Varios factores de distorsión geométrica y radiométrica pueden deberse al propio funcionamiento del sensor. Como ya vimos, los sensores de barrido electrónico realizan una exploración perpendicular a la trayectoria del satélite, gracias a un espejo oscilante que envía la radiancia registrada a una cadena de detectores sólidos. Este movimiento puede alterarse por anomalías del sensor, provocando un efecto de barrido no lineal o cambios en el intervalo de recogida de información, lo que implica transformar la resolución efectiva de la imagen.

Un segundo efecto debido al sensor se relaciona con el ángulo de barrido o campo de visión global. En el caso de sensores con un ángulo ancho de barrido (AVHRR o MODIS, por ejemplo), se presenta una distorsión panorámica amplia, tanto mayor cuanto más nos alejamos del nadir. En consecuencia, el tamaño del píxel varía sensiblemente desde el centro hacia los extremos de la imagen (en el caso del AVHRR, con un tamaño de píxel en el nadir de 1,1 × 1,1 km, se puede llegar en los extremos a un tamaño de 2,4 × 6,5 km: Goward *et al.*, 1991). Esto implica, junto a las deformaciones geométricas, una notable variación en las perturbaciones debidas a la atmósfera, ya que el espesor óptico cambia del nadir a los extremos. Cuando se trata de sensores con menor campo de visión (ETM o HRVIR), estos efectos son de menor calibre.

Otro problema frecuente que plantea el sensor es la falta de calibración entre detectores. En los sensores de barrido la exploración se realiza en varias líneas simultáneamente, por lo que requieren varios detectores por banda. Resulta muy importante que todos ellos traduzcan uniformemente la señal detectada, con objeto de que la misma radiancia recibida no se codifique en ND distintos. En ocasiones ese ajuste entre detectores se deteriora, provocándose un efecto de bandeado en la imagen final, especialmente perceptible en las zonas de baja radiancia (sombras, superficie marina). Para el caso de los equipos de exploración de empuje, el problema de calibración es aún mayor, ya que cuentan con un gran número de detectores por línea (6.000 para la banda pancromática del HRV). En este caso, un mal ajuste supondría un bandeado longitudinal en la imagen resultante. Más evidente todavía resultan los fallos momentáneos de alguno de los detectores, ya sea en la emisión (sensores activos), ya en la recepción de la señal. Esto provoca la pérdida de una serie de líneas o píxeles en la imagen final.

4. Distorsiones provocadas por las condiciones ambientales, principalmente el efecto de la atmósfera y el relieve. Como ya se comentó, los distintos elementos que componen la atmósfera causan una modificación de la radiancia original proveniente de la superficie terrestre. El efecto más importante es el de dispersión del flujo reflejado desde la superficie, a consecuencia de la presencia de aerosoles, gases y vapor de agua. Este efecto implica un aumento de la señal recibida por el sensor y es más sensible en las longitudes de onda cortas, que tienden a presentar un menor contraste entre coberturas de similar comportamiento radiométrico. En cuanto al relieve, supone una modificación, a veces severa, de la posición de los píxeles en la imagen, respecto a la esperable a partir de la posición del sensor.

Algunos de estos problemas se solventan rutinariamente en los centros encargados de la recepción o venta de las imágenes. Otros, sin embargo, persisten, haciendo precisas una serie de técnicas para subsanarlos. Por ejemplo, las correcciones atmosféricas son vitales para modelar parámetros físicos a partir de la imagen (6.2.3), generar índices espectrales (cap. 7, apdo. 1.2) o abordar estudios multi-temporales (cap. 7, apdo. 3). En este último caso, también son necesarias las correcciones geométricas, así como siempre que se pretenda relacionar la imagen con algún tipo de información auxiliar.

6.2. Correcciones radiométricas

Éste es un término muy genérico, que designa aquellas técnicas que modifican los ND originales, con objeto de acercarlos a los que habría presentes en la imagen caso de una recepción ideal. Dentro de este concepto hemos incluido el tratamiento de los problemas radiométricos derivados del mal funcionamiento del sensor, junto a la obtención de magnitudes físicas y corrección atmosférica de los datos.

6.2.1. *Restauración de líneas o píxeles perdidos*

Un mal funcionamiento del sensor o de la antena receptora de la imagen puede llevar a que ésta aparezca con algunas líneas o píxeles perdidos. En una visualización, la imagen presentaría una serie de líneas anómalas (negras o blancas), o incluso una serie de píxeles aislados de aspecto muy contrastado con los vecinos (efecto conocido como de «sal y pimienta»). En ambos casos se trata de información irreparablemente perdida. No puede restaurarse lo que nunca se obtuvo: por tanto, los procesos de corrección se dirigen aquí a mejorar artificialmente el aspecto visual de la imagen, facilitando su posterior interpretación.

La forma más lógica de estimar los ND de estos píxeles erróneos se basa en los ND de los píxeles vecinos. De acuerdo al conocido fenómeno de la auto-correlación espacial, muchas variables geográficas tienden a presentar una fuerte asociación en el espacio (Campbell, 1981; Cliff y Ord, 1973). La probabilidad de que aparezca una precipitación similar a la de una determinada estación, por ejemplo, es muy alta en estaciones cercanas, reduciéndose según nos alejamos de aquélla. De igual forma, los valores de radiancia provenientes de una parcela de la superficie terrestre tienden a estar positivamente correlacionados con los provenientes de parcelas vecinas. Por ello, parece razonable estimar los ND de las líneas perdidas a partir de los ND de las inmediatas. Este criterio de vecindad puede introducirse de distintas formas. La más sencilla es sustituir el ND de cada línea/píxel por el de los precedentes:

$$ND_{i,j} = ND_{i-1,j} \quad [6.16]$$

donde $ND_{i,j}$ corresponde al nivel digital del píxel de la línea i (la defectuosa) y columna, j, y $ND_{i-1,j}$, indica el nivel digital del píxel situado en la línea precedente. También podría incluirse $i + 1$, para sustituir las líneas defectuosas por las posteriores.

Un segundo método de sustitución promedia los valores de las líneas anterior y posterior a la defectuosa. Esto es:

$$ND_{i,j} = ENT\ \{(ND_{i-1,j} + ND_{i+1,j})/2\} \qquad [6.17]$$

en donde ENT { } indica que el resultado de la operación debe convertirse en el número entero más cercano. De acuerdo con Mather (1998), este segundo método resulta más arriesgado que el primero, sobre todo en aquellos casos en donde es menos claro asumir una auto-correlación espacial.

Un tercer método de recuperar la información perdida utiliza una banda auxiliar, altamente correlacionada con la que presenta problemas. A partir de esta banda auxiliar, se estima el valor de los píxeles defectuosos de la forma siguiente (Bernstein *et al.*, 1984):

$$ND_{i,j,k} = (s_k / s_r)\ \{ND_{i,j,r} - (ND_{i+1,j,r} + ND_{i-1,j,r})/2\} + (ND_{i+1,j,k} + ND_{i-1,j,k})/2 \qquad [6.18]$$

donde s_k y s_r son las desviaciones típicas de la banda a restaurar k y la banda auxiliar r, respectivamente. Al igual que en el caso anterior, el resultado debería convertirse al valor entero más cercano.

En cualquiera de los tres algoritmos [6.16 a 6.18] se asume que las líneas defectuosas ya han sido localizadas. Esto puede ser una tarea trivial en algunos casos, pero en otros resulta bastante complejo. Para ello puede emplearse un método de búsqueda automática, que parte de comparar la media aritmética de cada línea con la de las líneas anterior y posterior. Si difiere de ellas significativamente —esto es, por encima de un determinado umbral— se realiza un estudio más detallado de los ND que la componen, con objeto de detectar valores anómalos (0 o 255, por ejemplo). Si éstos aparecen, puede considerarse que aquella línea está afectada por algún tipo de error, y aplicarse sobre ella uno de los algoritmos previamente tratados.

Lo mismo cabe decir respecto a píxeles que muestren un valor anómalo, fruto de un error en la adquisición o recepción de los datos. En estos casos será aún más complicado localizar visualmente los píxeles erróneos. Lillesand y Kiefer (2000) proponen un método de búsqueda automática, basado en detectar aquellos píxeles que cuenten con un ND significativamente más alto o más bajo que el promedio de sus vecinos (calculado, normalmente, a partir de una ventana móvil de 3 × 3 píxeles). Caso de que el ND del píxel central de dicha ventana exceda, por encima o debajo de un cierto umbral, al ND medio de los píxeles vecinos, se sustituye por éste.

6.2.2. *Corrección del bandeado de la imagen*

En algunas imágenes obtenidas por equipos de barrido secuencial (sobre todo en los primeros sensores Landsat-MSS) se observa un bandeado de la imagen, especialmente perceptible en las zonas de baja radiancia (láminas de agua). Este bandeado, co-

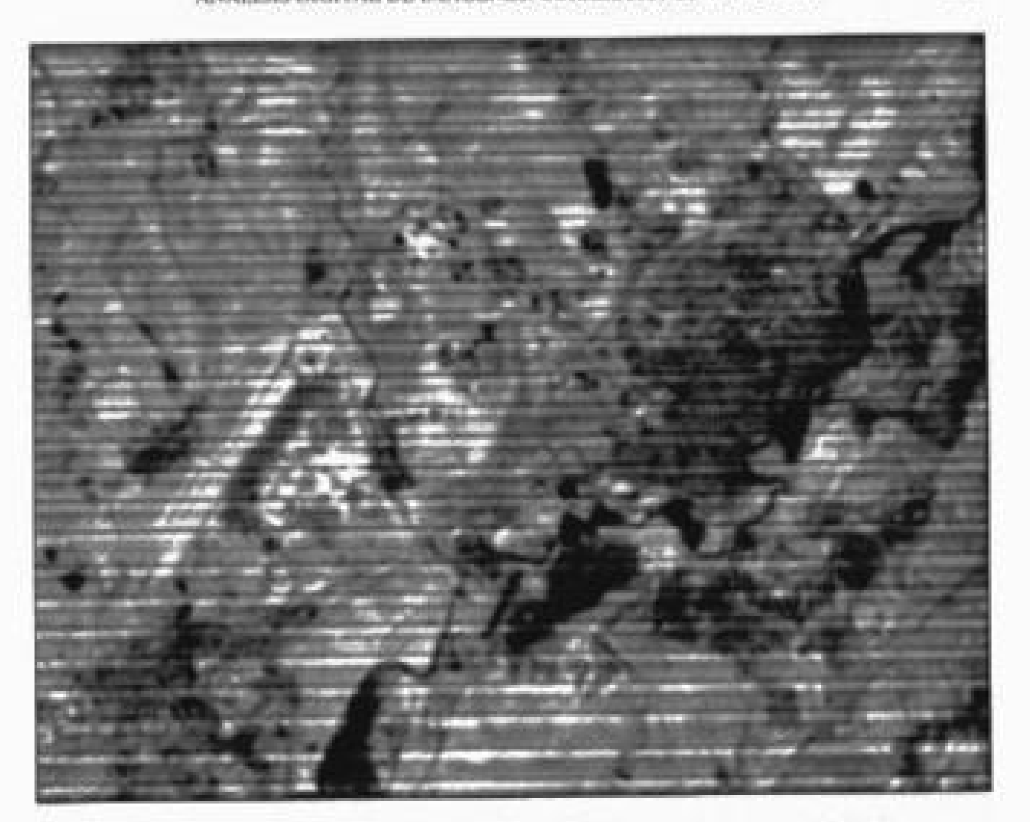


FIG. 6.25. *Efecto de bandeado en la banda térmica para la imagen Alcalá99.*

nocido como *striping* en la terminología anglosajona, se debe a un mal calibrado entre los detectores que forman el sensor; esto es, a que alguno de ellos codifique la radiancia que recibe en ND distintos a los demás. Los equipos de barrido multi-espectral exploran varias líneas simultáneamente a cada oscilación del espejo. Caso de que los detectores presenten inconsistencias, aparecerán en la imagen unas líneas más oscuras o claras que el resto (fig. 6.25). El efecto, además, es periódico, ya que cada detector registra 1 de cada p líneas, siendo p el número de detectores por banda. En el caso del sensor MSS se registraban 6 líneas simultáneamente, mientras este número se elevó a 16 para el TM. Para las imágenes tomadas por sensores de empuje, la calibración puede llega a ser aún más problemática, ya que para explorar simultáneamente una franja de terreno amplia el sensor cuenta con una cadena de detectores muy numerosa (varios miles, habitualmente). En este caso, una falta de calibración entre detectores se observará en una bandeado vertical, ya que cada columna de la imagen se adquiere por un detector distinto. La figura 6.26 recoge un claro ejemplo de este efecto, en este caso sobre una imagen tomada por el sensor ALI (a bordo del satélite EO-1) sobre la región argentina de Mendoza. Los coeficientes de calibración son específicos para cada columna de la imagen.

Para ajustar digitalmente la señal detectada por cada uno de los detectores se asume que todos ellos, caso de estar bien calibrados, tenderían a presentar similares histo-

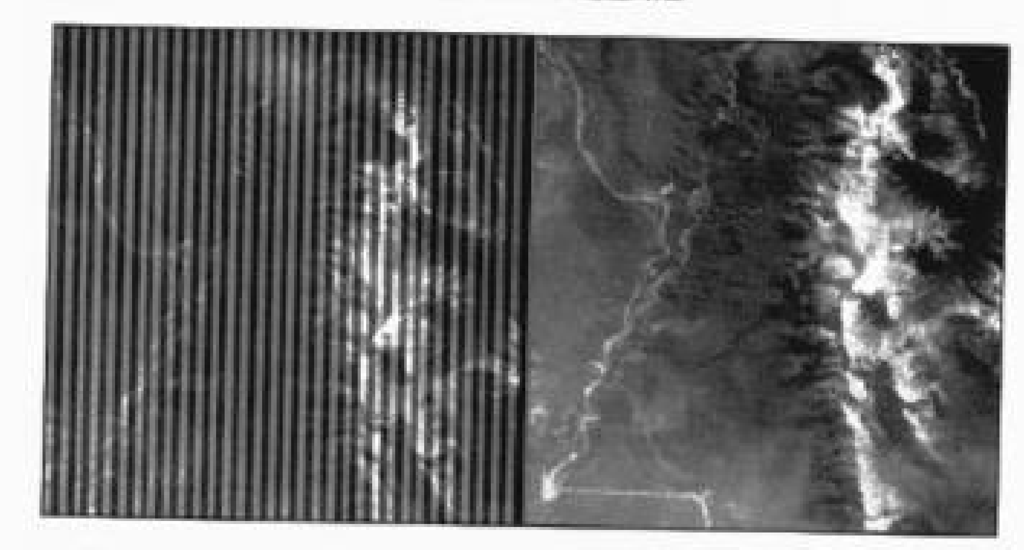


FIG. 6.26. *Problemas de calibrado en una imagen ALI. A la derecha los ND originales, a la izquierda los valores de radiancia calibrados. La imagen se adquirió sobre la provincia de Mendoza (Argentina) el 27 de marzo de 2001.* (Cortesía: Ruiliang Pu, U.C. Berkeley.)

gramas. Basta, por tanto, recomponer el histograma de cada detector, calculando la frecuencia de los *p* grupos de líneas independientemente (fig. 6.27). Por ejemplo, caso de trabajarse sobre una imagen MSS, con seis detectores por banda, se calcula, por un lado, el histograma de las líneas 1, 7, 13, 19, 25..., esto es, las recogidas por el primer detector; por otro, el correspondiente a las líneas 2, 8, 14, 20, 26... (segundo detector), y así sucesivamente hasta completar los seis detectores.

El paso siguiente intenta ajustar estos histogramas a otro que se elija como referencia. Lo más habitual es que el histograma de referencia sea el del conjunto de la imagen, formado por todas las líneas que la componen. La forma más sencilla de realizar el ajuste se basa en aplicar unos coeficientes lineales (sesgo y ganancia) a los histogramas de cada detector, con objeto de igualar sus medias y desviaciones típicas con las del histograma de referencia. Aunque existen otros procedimientos no lineales (considerando el histograma acumulativo), el método lineal ofrece, en la mayor parte de los casos, buenos resultados.

Su proceso parte de calcular la media y desviación típica de cada histograma parcial: esto es, del correspondiente a los píxeles codificados por un determinado detector. Posteriormente, para ajustar estos valores a los encontrados para el histograma de referencia basta aplicar:

$$b_i = s / s_i \qquad [6.19]$$

y

$$a_i = \overline{ND} - b_i \overline{ND}_i \qquad [6.20]$$

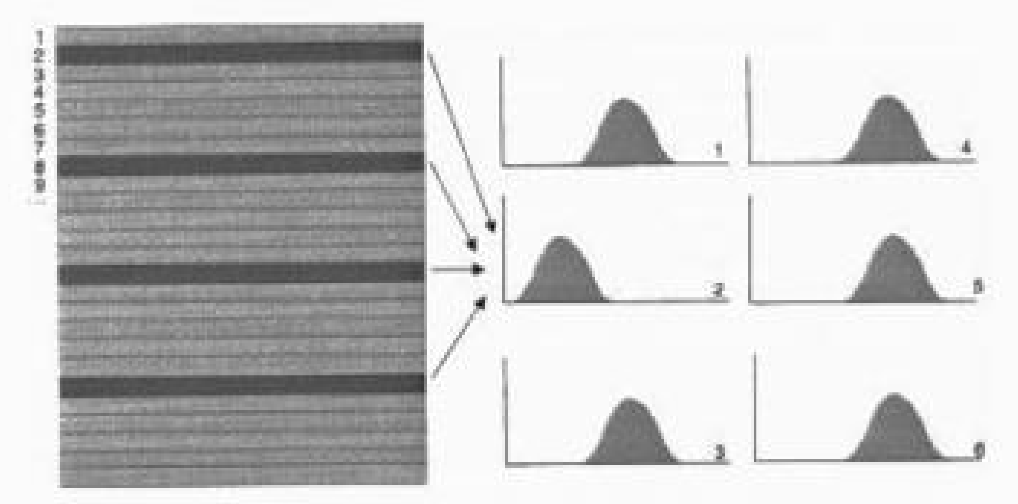


FIG. 6.27. *Para corregir el bandeado de la imagen se calculan histogramas parciales de cada conjunto de p líneas de la imagen, siendo p el número de detectores.* (Adaptado de Campbell, 1996.)

donde s y s_i indican las desviaciones típicas del histograma de referencia y parcial, respectivamente; $\overline{ND}$ y $\overline{ND}_i$, los ND medios para ambos, y a_i y b_i los coeficientes de ajuste. A partir de estos coeficientes puede calcularse el valor corregido, aplicando una sencilla función:

$$ND'_{i,j} = a_i + b_i ND_{ij} \qquad [6.21]$$

en donde el ND de salida se calcula a partir de aplicar unos coeficientes de ajuste al ND de entrada. Para reducir el volumen de cálculos, este algoritmo suele aplicarse a partir de una técnica muy similar a las tablas de color (CLUT) que vimos anteriormente.

6.2.3. *Cálculo de reflectividades*

La conversión de los ND almacenados en una imagen original a variables físicas es un paso previo que resulta de gran utilidad en múltiples fases de la interpretación de imágenes, ya que permite trabajar con variables físicas de significado estándar, comparables en un mismo sensor a lo largo del tiempo, entre distintos sensores y entre la teledetección espacial y otros métodos de detección de energía electromagnética. El primer aspecto resulta relevante cuando pretendamos abordar tareas de detección de cambios; el segundo es clave para integrar información espectral procedente de distintos equipos (por ejemplo, en tareas de fusión de imágenes. Finalmente, el tercero es crítico si queremos comparar nuestros datos con los obtenidos por teledetección aérea o radiómetros de campo (por ejemplo, con las librerías espectrales que vimos en cap. 2, apdo. 5.5).

Naturalmente podemos afirmar que esa información ya está contenida en los ND originales, pero conviene considerar que sólo de modo relativo. En otras palabras, la relación numérica está circunscrita a cada banda de la imagen (ahí sí es cierto que a

mayor ND, mayor reflectividad, sin considerar el efecto del relieve), pero no sirve para comparar bandas entre sí (un mayor ND entre dos bandas, no indica necesariamente mayor reflectividad), ni en imágenes de distintas fechas o sensores. Por el contrario, la reflectividad o temperatura son variables físicas comparables entre lugares y fechas, lo que hace más sólida la interpretación de los datos, garantiza la compatibilidad multitemporal y el análisis integrado con imágenes de distintos sensores (lógicamente, siempre que abarquen las mismas bandas del espectro).

La obtención de esas variables requiere resolver satisfactoriamente la acción de varios factores. Algunos hacen referencia al propio sensor (calibrado de las radiancias), para lo que es imprescindible contar con información de la entidad que lo gestiona, otras a las condiciones de observación (ángulos de iluminación y adquisición), y otras a elementos del ambiente (efecto atmosférico y topográfico, iluminación procedente de otras cubiertas). Intentaremos analizar estos diversos factores, proponiendo tratamientos que, dentro de una cierta simplicidad, permitan solventar eficazmente sus efectos.

6.2.3.1. Reflectividad aparente: modelo simplificado

Definimos en el capítulo 2 la reflectividad como la relación entre la energía reflejada y la incidente. Varía, por tanto, entre 0 (superficie perfectamente absorbente) y 1 (superficie perfectamente reflectora). Como también sabemos, la reflectividad de una cubierta depende de sus características físicas y químicas, así como de las condiciones de observación. Además no es constante, sino que se modifica en las distintas bandas del espectro, por lo que debemos añadirle el calificativo de espectral, acotando su medida a un determinado rango de longitudes de onda. Precisamente, en el análisis de cómo varía la reflectividad espectral de una cubierta encontramos la raíz para poder discriminarla.

De acuerdo a la definición antes recordada, para conocer la reflectividad de una superficie es preciso relacionar dos magnitudes: la energía reflejada y la incidente. A partir de los datos medidos por el sensor podemos obtener la primera, ya que la radiancia espectral medida por éste es consecuencia de la reflexión de la radiación solar procedente del suelo. Esa medición se codifica a un valor numérico (el ND), de acuerdo a unos coeficientes de calibración específicos para cada sensor. Ya que estos coeficientes son conocidos, puede realizarse el proceso inverso, obteniendo los valores de radiancia espectral detectada por el sensor a partir de los ND:

$$L_{sen,k} = a_{0,k} + a_{1,k} \mathrm{ND}_k \qquad [6.22]$$

donde $L_{sen,k}$ corresponde a la radiancia espectral recibida por el sensor en la banda k (en $W\, m^{-2}\, sr^{-1}\, \mu m^{-1}$); $a_{0,k}$ y $a_{1,k}$ son los coeficientes de calibración para esa banda, y ND_k corresponde al nivel digital de la imagen en la misma banda. Estos coeficientes de calibrado suelen incluirse en la cabecera de la imagen. En la tabla 6.5 aparecen los correspondientes a los sensores TM y ETM+.

Por otro lado, la radiancia que llega al sensor —asumiendo que la superficie terrestre tiene un comportamiento lambertiano— es una función de la irradiancia solar, la reflectividad de la cubierta y las condiciones de adquisición (fig. 6.28):

TABLA 6.5. *Parámetros para la conversión a reflectividades de imágenes Landsat**

		Landsat-5 TM		*Landsat-7 ETM+*	
Banda	$E_{0,k}$ ($W m^{-2} \mu m^{-1}$)	$a_{0,k}$	$a_{1,k}$	$a_{0,k}$	$a_{1,k}$
1	1.957	–1,5	0,602	–6,2	0,786
2	1.829	–2,8	1,17	–6,0	0,817
3	1.557	–1,2	0,806	–4,5	0,639
4	1.047	–1,5	0,815	–4,5	0,635
5	219,3	–0,37	0,108	–1,0	0,128
7	74,52	–0,15	0,057	–0,35	0,044

* Los valores de irradiancia solar y calibración del TM se han tomado de Price (1987). Estos parámetros de calibración corresponden a las imágenes TM del Landsat-4 posteriores a 1984 y a todas las del Landsat-5. Para coeficientes de calibración previos puede consultarse ese artículo de Price. Para ETM+, los valores de calibración se han tomado de la cabecera de la imagen.

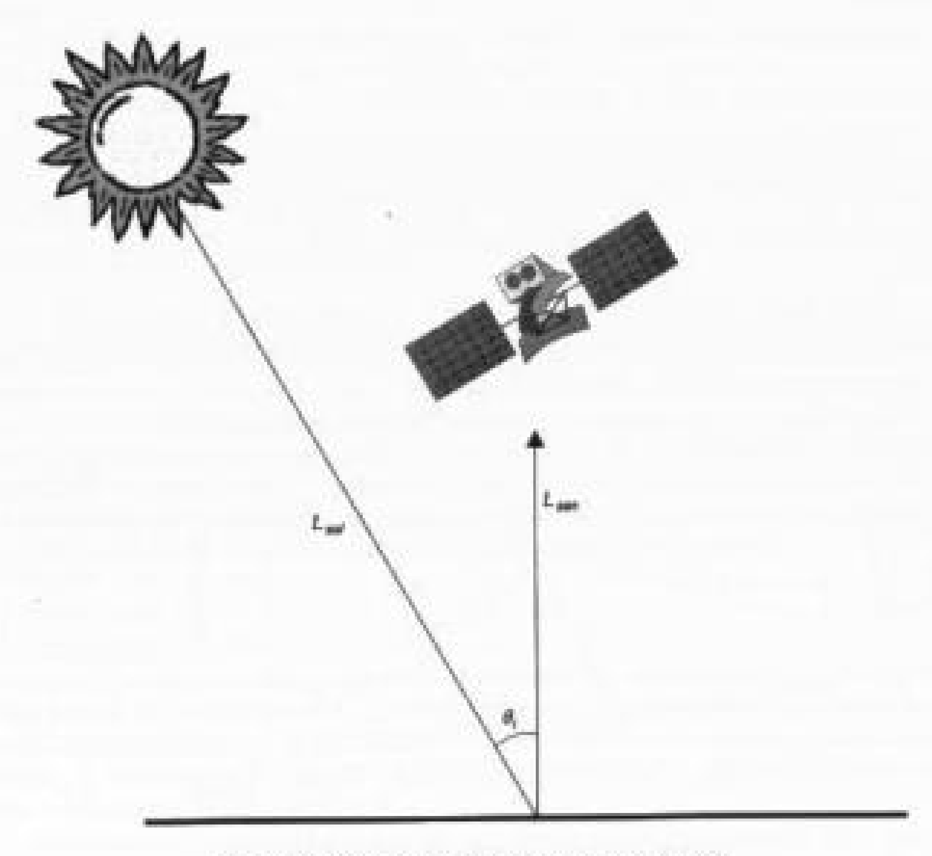


FIG. 6.28. *Cálculo simplificado de la reflectividad.*

$$L_{sen,k} = \frac{E_{0,k} \cos\theta_i \rho^*_k}{D\pi} \quad [6.23]$$

donde $E_{0,k}$ es la irradiancia solar en el techo de la atmósfera (para esa banda del espectro), conocida a partir de las tablas solares (tabla 6.5); ρ^*_k es la reflectividad aparente de la cubierta en esa banda k; θ_i es el ángulo cenital del flujo incidente, formado por la vertical al terreno y los rayos solares. En modelos simplificados, como el que estamos ahora presentando, este ángulo se equipara al ángulo cenital solar (el complementario del ángulo de elevación solar, que se incluye en la cabecera de la imagen), lo que supone asumir que el terreno es llano. Finalmente, D es el factor corrector de la distancia Tierra-Sol, calculado como:

$$D = (1 + 0{,}01674\,(\mathrm{sen}\,(2\pi\,(J - 93{,}5) / 365)))^2 \quad [6.24]$$

donde J indica el día en el calendario juliano y el seno se asume que toma los valores del ángulo en radianes. Este factor varía, aproximadamente, entre 0,983 (3 de enero) en el perihelio y 1,017 (4 de julio) en el afelio.

En definitiva, la reflectividad aparente puede calcularse a partir de una sencilla fórmula:

$$\rho^*_k = \frac{D\pi L_{sen,k}}{E_{0,k} \cos\theta_i} \quad [6.25]$$

Por tanto, el proceso de traducción de ND a reflectividades se realiza en dos fases: 1) conversión de ND a valores de radiancia ($L_{sen,k}$), a partir de los coeficientes de calibrado del sensor, y 2) estimación de valores de reflectividad aparente (ρ^*_k), conociendo la irradiancia solar y la fecha de adquisición (de la que se estima D y el ángulo cenital θ_i).

Como puede observarse en la figura 6.29, la transformación simple de ND a reflectividad únicamente modifica las diferencias de calibración entre bandas de la misma imagen y cambia la escala de medición a un parámetro físico, pero no permite corregir efectos atmosféricos, o aquéllos debidos a la influencia de cubiertas vecinas, a los ángulos de observación o las condiciones de iluminación. En definitiva, la reflectividad aparente asume que la observación se realiza en una atmósfera transparente, verticalmente, sobre suelo plano y superficies perfectamente lambertianas.

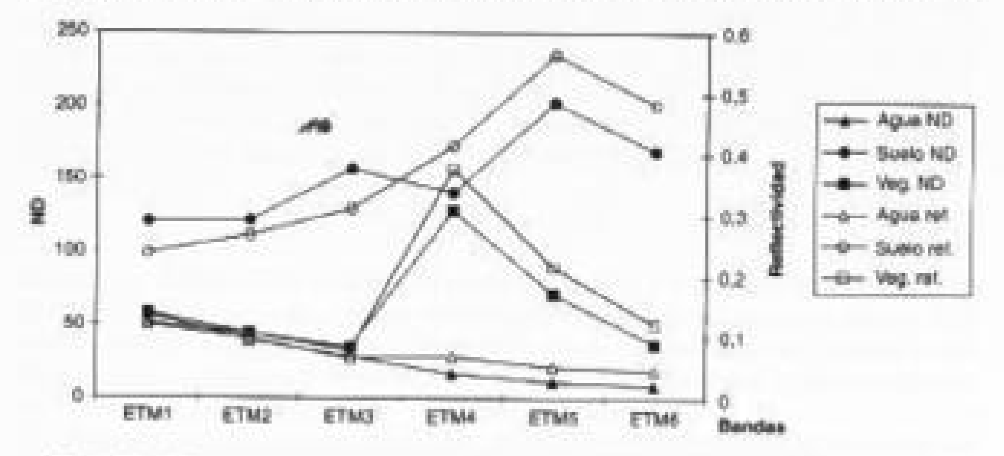


FIG. 6.29. *Comparación entre las curvas espectrales de los ND brutos y con reflectividad aparente para el agua, suelo descubierto y vegetación.*

Como ya indicamos en el capítulo 2, los componentes de la atmósfera producen un efecto de absorción y dispersión, que modifican, a veces notablemente, la señal procedente de la cubierta. Además, este efecto es dependiente de la longitud de onda —afectando especialmente a las más cortas—, por lo que no puede prescindirse de él, ni siquiera para realizar transformaciones entre bandas. También dependiente de la atmósfera es el denominado efecto de adyacencia, que implica que se reciba energía procedente de cubiertas vecinas. Este efecto reduce el contraste de la escena y puede dificultar la discriminación entre objetos vecinos (Itten y Meyer, 1993). Por otra parte, la observación vertical puede asumirse para buena parte de los sensores de interés ambiental (Landsat-MSS, TM, ETM+, IRS-LISS, ...), pero no siempre para otros que poseen la capacidad de observar áreas oblicuamente, de cara a mejorar su cobertura temporal o plantear modelos estereoscópicos, como ocurre con el SPOT-HRV, o con el NOAA-AVHRR, con un ángulo muy amplio de barrido. En tercer lugar, el terreno plano sólo es asumible cuando las pendientes sean realmente bajas (< 5°) y no existan variaciones de iluminación por efecto de la vertiente. Finalmente, el carácter lambertiano de las cubiertas es tanto menos nítido cuanto menos rugosas sean.

En los siguientes epígrafes comentaremos el efecto de estos factores sobre la señal recibida por el sensor y plantearemos algunos métodos prácticos para abordar su corrección. Dividiremos este comentario en tres grandes factores: la atmósfera, el efecto del relieve y el carácter direccional de la reflectividad.

6.2.3.2. Correcciones atmosféricas

La influencia atmosférica no afecta por igual a los dos componentes del cálculo de la reflectividad: flujo descendente (denominador) y ascendente (numerador), ya que el espesor de la atmósfera que atraviesan es distinto. Además, hay que considerar que a la irradiancia solar directa (la medida en las tablas) hay que añadir la difusa, procedente de otros objetos vecinos (E_d en la fig. 6.30). En definitiva, la radiancia que recibe el satélite no es la misma que sale del suelo (ésta es la que interesa, pues pretendemos medir la reflectividad de la cubierta, no la influida por la atmósfera), sino que es fruto de los siguientes parámetros (Gilabert *et al.*, 1994):

$$L_{sen,k} = L_{su,k}\,\tau_{k,o} + L_{a,k} \quad [6.26]$$

donde $L_{su,k}$ es la radiancia que sale de la superficie; $\tau_{k,o}$, la trasmisividad de la atmósfera para el flujo ascendente, y $L_{a,k}$ la radiancia aportada por la dispersión atmosférica. La transmisividad en la dirección ascendente depende del espesor óptico de ozono ($\tau_{oz,k}$), de aerosoles ($\tau_{a,k}$), y del espesor óptico molecular ($\tau_{r,k}$) para esa misma banda, y del ángulo de observación (θ_o):

$$\tau_{k,o} = \exp\left((-\tau_{oz,k} - \tau_{a,k} - \tau_{r,k}) / \cos\theta_o\right) \quad [6.27]$$

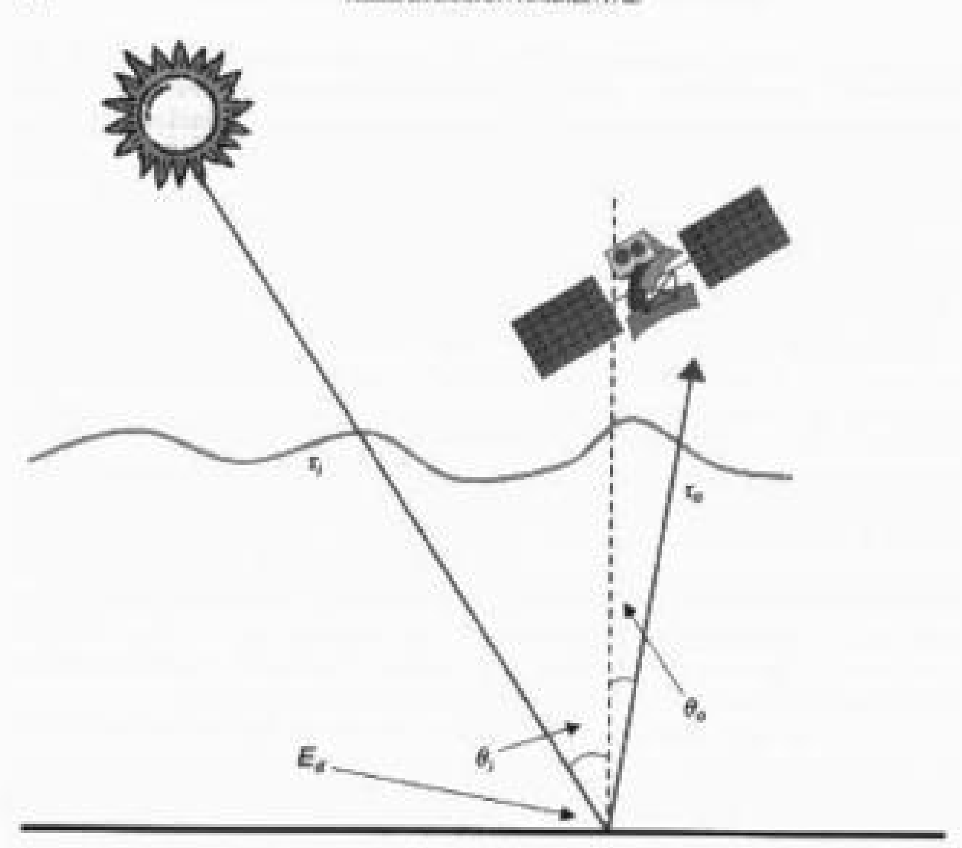


FIG. 6.30. *Efectos atmosféricos sobre el cálculo de la reflectividad.*

El ángulo de observación sólo debe considerarse cuando la adquisición no es vertical, como ocurre en algunas tomas del SPOT-HRV, o para ángulos de abertura muy amplios, caso del AVHRR.

Respecto al flujo incidente, tampoco resulta fidedigno el parámetro indicado en [6.25], ya que la irradiancia que llega al suelo ($E_{su,k}$) no es la que medimos en el techo de la atmósfera ($E_{0,k}$) sino que también está afectada por la atmósfera y por el componente de luz difusa:

$$E_{su,k} = E_{0,k} \cos\theta_i \tau_{k,i} + E_{d,k} \qquad [6.28]$$

donde $E_{0,k}$ y $\cos\theta_i$ tienen el mismo significado de [6.25]; $\tau_{k,i}$ es la transmisividad atmosférica que afecta al rayo incidente, y $E_{d,k}$ es la irradiancia difusa, como consecuencia de la dispersión Rayleigh y Mie, que también depende de las condiciones de la atmósfera.

La transmisividad del rayo incidente tiene una expresión similar a la que afecta al flujo reflejado, cambiando el ángulo de observación por el de incidencia (θ_i):

$$\tau_{k,i} = \exp((-\tau_{mr,k} - \tau_{a,k} - \tau_{v,k}) / \cos\theta_i) \qquad [6.29]$$

En suma, para conocer la reflectividad real de la cubierta, definida por:

$$\rho_k = \frac{D\pi L_{su,k}}{E_{su,k}} \qquad [6.30]$$

es preciso resolver la siguiente fórmula (a partir de [6.26] y [6.28]):

$$\rho_k = \frac{D\pi((L_{sen,k} - L_{a,k}) / \tau_{k,o})}{E_{o,k} \cos\theta_i \tau_{k,i} + E_{d,k}} \qquad [6.31]$$

En definitiva, para calcular la reflectividad de la superficie necesitamos estimar la transmisividad de la atmósfera (descendente, $\tau_{k,i}$, y ascendente, $\tau_{k,o}$), la irradiancia difusa ($E_{d,k}$) y la radiancia atmosférica debida a la dispersión ($L_{a,k}$).

Los procedimientos para abordar estas correcciones con exactitud son muy laboriosos y requieren datos sobre las condiciones de la atmósfera en el momento de tomar la imagen, que no suelen estar disponibles. Además, el efecto de la atmósfera no es constante en la imagen, sino que determinadas zonas pueden haber sido más afectadas que otras, en función de la diversa presencia de aerosoles o vapor de agua.

Hasta el momento, las correcciones atmosféricas se han abordado siguiendo cuatro procedimientos (King *et al.*, 1999; Robin, 1998; Sobrino, 2000):

1. A partir de medidas *in situ*, ya sean referidas a perfiles de la composición atmosférica mediante radiosondeos, ya a estimaciones cualitativas del espesor óptico (midiendo, por ejemplo, la visibilidad), o mediante mediciones en terreno de la radiancia solar incidente o de la reflectividad en el terreno. Estos métodos resultan, en general, los más precisos, por cuanto facilitan una medición de las condiciones atmosféricas durante la toma de la imagen, pero rara vez están disponibles.
2. A partir de imágenes de otros sensores, que permitan estimar el estado de la atmósfera en el momento de adquisición de las imágenes. Pese a la gran lógica de este planteamiento: dos sensores, uno mide los objetos de interés, y otro mide la atmósfera cuando se toman los datos, este enfoque resulta bastante novedoso, ya que sólo muy recientemente se han diseñado misiones con esta concepción. Por ejemplo, la plataforma Terra, como ya hemos visto, incluye sensores que miden específicamente el espesor atmosférico (el MISR), simultáneamente a otros orientados a medición de reflectividad o temperatura (como el MODIS). Si bien la resolución espacial de esos sensores no es la misma, la integración entre estos datos resulta muy beneficiosa para obtener productos calibrados de adecuada fiabilidad (King *et al.*, 1999). No obstante, todavía hay pocas experiencias prácticas de este planteamiento.
3. A partir de modelos físicos de transferencia radiativa, que suelen basarse en una serie de atmósferas estándar. La exactitud de los modelos dependerá, como es lógico, de la solidez de las asunciones que se realicen y de la similitud entre los perfiles teóricos y las condiciones concretas de la atmósfera cuando se toma la imagen.
4. A partir de datos de la propia imagen. Éste sería, sin duda, el método más operativo, pues no requeriría información externa y facilitaría una corrección completa de los datos.

De las cuatro posibles soluciones al problema de la corrección atmosférica nos vamos a centrar en este epígrafe en las dos últimas, pues resultan, por el momento, las más accesibles. En lo que se refiere al empleo de modelos de transferencia radiativa con atmósferas estándar, existen ya algunos programas bastante operativos, que realizan la estimación del efecto atmosférico con bastante fidelidad, siempre y cuando se dé una buena similitud entre las condiciones atmosféricas de la imagen y las estándar incluidas en el modelo. Sin duda, los modelos más conocidos son el 6S (Vermote *et al.*, 1997) y el MODTRAN4 (Berk *et al.*, 1999). Ambos cuentan ya con numerosas versiones (aquí se han citado las últimas) que van enriqueciendo las asunciones que inicialmente se plantearon en su diseño. El 6S (segunda simulación de la señal de satélite en el espectro solar) fue desarrollado inicialmente por el laboratorio de óptica atmosférica de la Universidad de Lille. En la última versión simula observaciones planas, considera la elevación, permite tener en cuenta el carácter no lambertiano de la superficie, e incluye nuevos gases (CH_4, N_2, O, CO) en el cálculo de la transmisión gaseosa. Facilita una estimación del efecto atmosférico para todo el espectro óptico, con bandas de hasta 0,025 µm de anchura. Por su parte, el MODTRAN4 es una nueva versión de un modelo desarrollado por la fuerza aérea norteamericana junto a una empresa privada (*Spectral Sciences, Inc*). También considera los efectos de reflectividad bidireccional (BRDF) en terreno y de reflectividad de objetos cercanos (adyacencia).

Desde el punto de vista de su clara operatividad también conviene destacar el modelo ATCOR, desarrollado por Richter (1996; 1997), incluido entre los módulos del programa *PCI-Geomatics*. Este modelo basa la corrección en una serie de perfiles atmosféricos estándar, que se incluyen con el programa, aunque son fácilmente adaptables por el usuario en caso de que se cuente con información más detallada. Estas definiciones incluyen el contenido de vapor de agua y el tipo de aerosoles. El programa requiere únicamente una estimación del espesor atmosférico, indicando un rango de visibilidad (en km), y una altura promedio de la zona (si bien también puede incorporarse un MDT). Incluye los coeficientes de calibración estándar para el SPOT-HRV y el Landsat-TM, pero el usuario puede incluir fácilmente los correspondientes a otros sensores. También se precisa introducir el ángulo cenital solar. El programa incluye opcionalmente una estimación del efecto de adyacencia, que es causada por la dispersión procedente de cubiertas vecinas, a partir de considerar las diferencias entre la reflectividad del píxel y la correspondiente a los alrededores (en este caso se considera un área de 1 × 1 km). El autor advierte que este modelo sólo funciona adecuadamente para sensores de observación cuasi vertical (se acepta una tolerancia de ± 8°), en zonas por debajo de 1.500 m de altitud y con pendientes moderadas.

Naturalmente, lo ideal sería poder derivar la corrección atmosférica de los datos de la propia imagen, si consiguiéramos encontrar alguna función que extrajera de la señal detectada por el sensor la parte correspondiente a las condiciones atmosféricas. Las alternativas para llevar a cabo esta tarea se pueden resumir en cuatro posibilidades: estimar la contribución de la atmósfera a partir de cubiertas que deberían presentar una reflectividad nula (métodos basados en el «objeto oscuro»); estimar el efecto atmosférico a partir de las diferencias de absorción y dispersión en distintas bandas del espectro para la misma imagen; realizar una homogeneización multitem-

poral entre imágenes[5] y observar la misma zona con distintos ángulos. Esta última vía, que ya hemos comentado en anteriores capítulos, sólo ha estado disponible en los últimos años, gracias a disponer de sensores con capacidad multiangular. El análisis multitemporal lo trataremos más adelante (cap. 7, apdo. 3). La estimación de las condiciones de la atmósfera a partir de la observación multibanda se ha desarrollado ampliamente en la corrección de imágenes térmicas, como luego comentaremos (6.2.4). En consecuencia, nos detendremos aquí únicamente en la primera opción, que resulta una de las más sencillas.

La propuesta inicial de los métodos basados en el objeto oscuro *(dark object)* fue realizada por Chavez en 1975, con sucesivas mejoras en 1988 y 1996 (Chavez, 1975, 1988, 1996). El punto de partida del método consiste en asumir que las áreas cubiertas con materiales de fuerte absortividad (agua, zonas en sombra) deberían presentar una radiancia espectral muy próxima a cero. En la práctica, el histograma de los ND de la imagen siempre presenta un mínimo superior a ese valor, que se atribuye al efecto de dispersión atmosférica. Asimismo, se observa que ese valor mínimo es mayor en las bandas más cortas, disminuyendo hacia el IRC y SWIR. Como ya vimos, la dispersión Rayleigh —la más común— afecta principalmente a las longitudes de onda más cortas, lo que confirma que ese valor mínimo puede corresponder más al efecto de la atmósfera que a la radiancia espectral proveniente de la superficie terrestre. En suma, una sencilla aproximación a la corrección atmosférica consiste en restar a todos los ND de cada banda el mínimo de esa misma banda, situando el origen del histograma en cero:

$$ND'_{i,j,k} = ND_{i,j,k} - ND_{min,k} \quad [6.32]$$

donde $ND_{min,k}$ indica el valor mínimo de cada banda. Esto, en definitiva, supone estimar el parámetro $L_{a,k}$ en la fórmula [6.31] a partir del valor mínimo del histograma. La asunción puede ser bastante correcta siempre que tengamos en la imagen zonas en sombra o con agua profunda. Incluso se puede plantear establecer una red de superficies oscuras en la imagen y realizar luego una interpolación para tener mejor en cuenta la variedad espacial del espesor atmosférico (Ouaidrari y Vermote, 1999).

El método del objeto oscuro resulta muy sencillo, y es válido para estimar el espesor atmosférico de aerosoles, pero los errores pueden ser notables para valores de reflectividad altos (por encima del 15 %), al no considerar las transmisividades del flujo incidente y reflejado. Para evitar este problema se ha sugerido complementarlo con estimaciones en el terreno de la transmisividad o con parámetros climáticos auxiliares (principalmente para estimar el contenido de vapor de agua y de ozono: Ouaidrari y Vermote, 1999). De hecho, la última versión de la propuesta de Chavez sugiere estimar la transmisividad descendente a partir del espesor atmosférico definido por el coseno del ángulo cenital (θ_i) (Chavez, 1996). Además, al igual que en la versión previa, el autor sugiere no considerar la irradiancia difusa. En pocas palabras, para observaciones verticales, la fórmula [6.31] quedaría como:

5. En este caso puede que baste con corregir los efectos atmosféricos sólo de modo relativo, de tal forma que las imágenes sean comparables entre sí.

$$\rho_k = \frac{D\pi(L_{sen,k} - L_{a,k})}{E_{o,k}\cos\theta_i^2} \qquad [6.33]$$

donde $L_{a,k}$ se estimaría a partir del valor mínimo o de un objeto de reflectividad nula ($L_{a,k} = a_{0,k} + a_{1,k}\,ND_{min}$). El autor asume que la transmisividad ascendente es 1, lo cual parece razonable para observaciones verticales.

Este modelo sólo se ha demostrado eficaz para las bandas TM 1, 2, 3 y 4. La transmisividad descendente aumenta con la longitud de onda. El valor de la transmisividad es independiente, según el modelo, de la longitud de onda, por lo tanto en principio se corrige poco la banda TM1 y mucho la banda TM4. Sin embargo, la corrección resulta satisfactoria y este error no es significativo (Chavez, 1996). La transmisividad se hace prácticamente 1 para TM5 y 7 (Gilabert *et al.*, 1994), con lo que en estas bandas la corrección del coseno no sería aplicable porque dichas bandas quedarían demasiado corregidas. Finalmente, el mismo autor propone también utilizar unos valores de transmisividad estándar, en lugar de la corrección del coseno. La fórmula propuesta, en este caso, quedaría finalmente como:

$$\rho_k = \frac{D\pi(L_{sen,k} - L_{a,k})}{E_{o,k}\cos\theta_i\,\tau_{k,i}} \qquad [6.34]$$

donde $\tau_{k,i}$ = 0,70 (TM1), 0,78 (TM2), 0,85 (TM3), 0,91 (TM4) y 1 para las bandas del SWIR (TM5 y 7). Estos valores de $\tau_{k,i}$ son muy similares a los propuestos por otros autores. Gilabert *et al.* (1994) sugieren, respectivamente, 0,73, 0,79, 0,85, 0,91, 0,95 y 0,97 para las mismas longitudes de onda. Pons y Solé (1994) también proponen unos valores promedio de transmisividad, similares a los anteriores, aunque se matizan en función del ángulo cenital solar.

En la figura 6.31 se incluye una comparación gráfica entre las reflectividades calculadas por el método de Chavez (con transmisividades promedio) y las que obtuvimos en el epígrafe anterior (reflectividad aparente). El efecto de la corrección resulta bastante obvio, sobre todo en lo que se refiere a la banda azul, en donde los valores decrecen notablemente. Además se observa el comportamiento típico de la vegetación con las bandas de absorción en el azul y rojo, que quedaban muy distorsionadas por el efecto atmosférico en la reflectividad aparente. También el agua presenta una curva de reflectividad más similar a lo esperable, con valores bajos y descendentes hacia longitudes más largas, si bien aquí puede haberse producido una sobre-corrección de la banda azul. En la siguiente figura (6.32) se comparan los métodos de Chavez y Richter (ATCOR) para las mismas cubiertas que hemos visto en anteriores gráficos. Como puede observarse, el efecto de la corrección es bastante comparable entre métodos, especialmente en agua y vegetación. No obstante, se observa que el método de Chavez infraestima la transmisividad en la banda roja, como se muestra en que la vegetación no ofrezca una banda de absorción en relación con el verde, y el trazado anómalo de la curva del suelo. Ambas parecen sobre-estimar el efecto atmosférico en la banda azul. La comparación entre ellas requeriría un análisis más detallado, aplicado a imágenes de distintas fechas. Se aplicaron estos dos métodos a dos imágenes Landsat-TM sobre

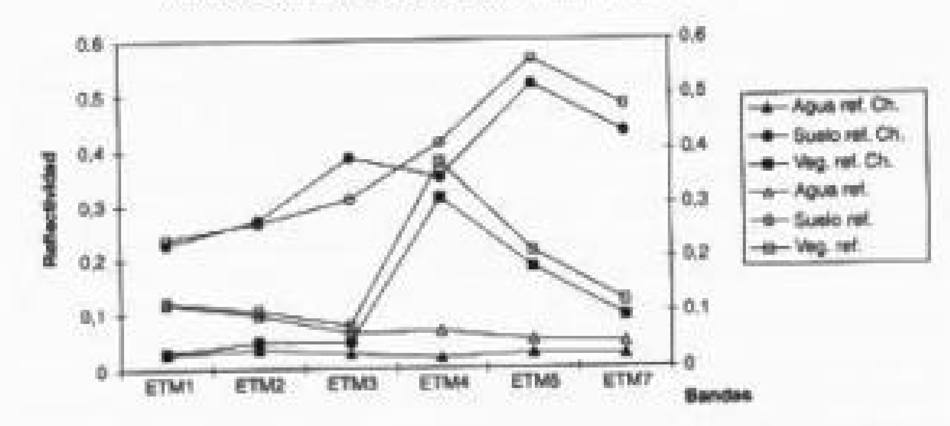


FIG. 6.31. *Comparación entre las curvas de reflectividad aparente y las corregidas atmosféricamente (método Chavez).*

imágenes de verano en el centro de la Península, observándose que el ATCOR sobre-estimaba la corrección en las bandas cortas (ofreciendo incluso valores negativos), frente a una infra-estimación en el NIR y SWIR (Riaño, 2000).

6.2.3.3. Correcciones del sombreado topográfico

Otro elemento importante que conviene considerar en el cálculo de reflectividades es el efecto del relieve. La reflectividad es muy dependiente de los ángulos de incidencia y observación. Hemos asumido hasta aquí que el ángulo de la radiación incidente sólo depende de la elevación solar, lo que implica considerar un terreno llano. La asunción, como es lógico, sólo será válida si realmente se trata de una superficie de escasa pendiente, siendo arriesgada cuando no sea así. Los efectos derivados del gradiente y dirección de la pendiente son bastante notorios, especialmente en las zonas en sombra. La creciente disponibilidad de modelos digitales de elevación (MDE) permite

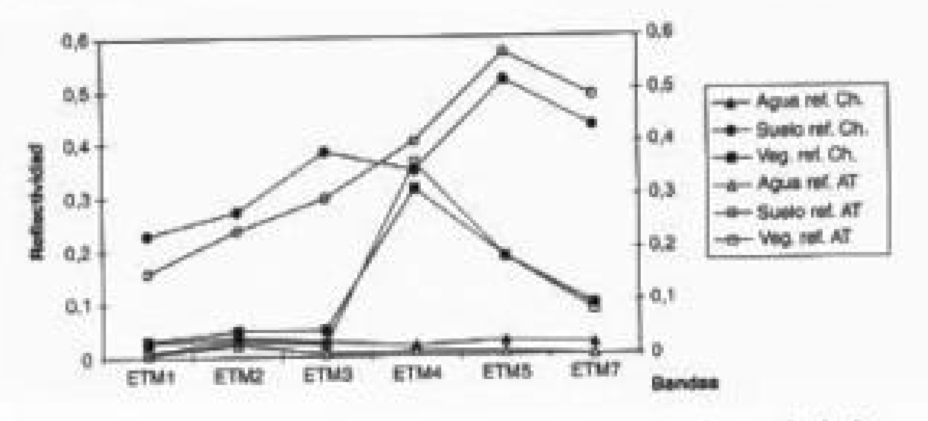


FIG. 6.32. *Comparación entre las curvas de reflectividad obtenidas por el método de Chavez y por el ATCOR.*

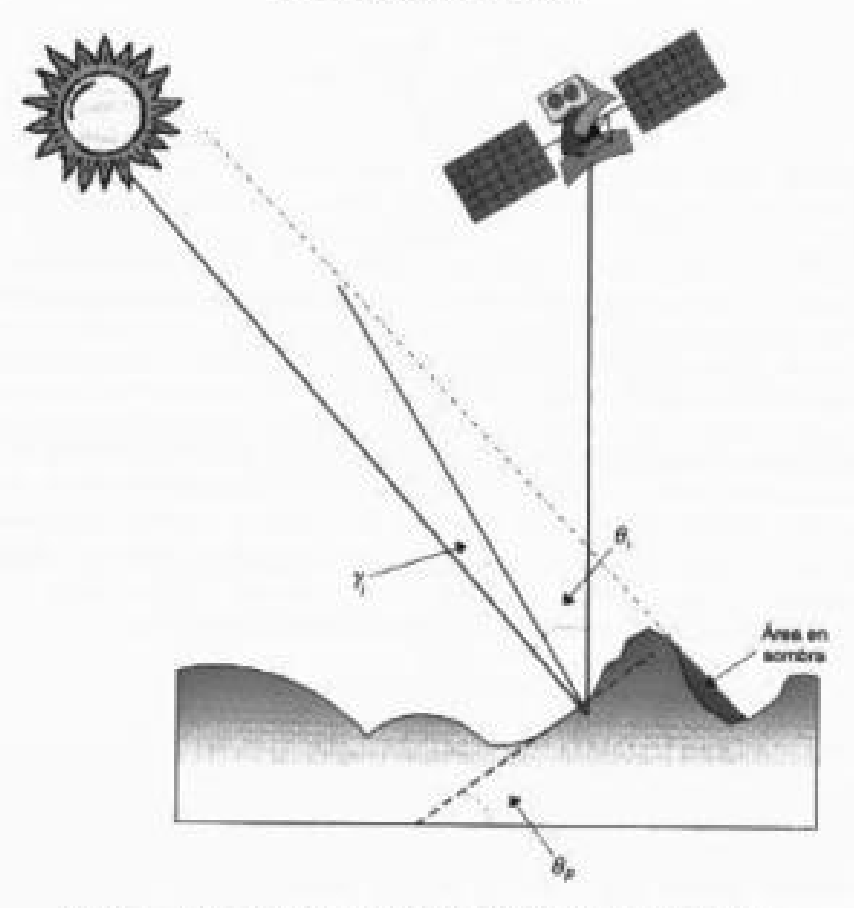


FIG. 6.33. *Efecto del relieve sobre la radiancia detectada por el sensor.*

abordar con ciertas garantías esta corrección, homogeneizando la señal de la misma cubierta independientemente de la vertiente en que se encuentre.

Repasando la figura 6.28 podemos observar cómo la energía incidente está en función del ángulo cenital solar (θ_i). La máxima energía para una determinada banda se obtiene cuando el ángulo cenital es de 0 grados ($\cos \theta_i = 1$), esto es cuando el sol incide verticalmente. El ángulo cenital, como ya indicamos, se calcula como el complementario del ángulo de elevación solar, que suele recogerse en la cabecera de la imagen. Ahora bien, en un terreno montañoso la pendiente modifica la geometría del flujo incidente (fig. 6.33). Por un lado, en las laderas orientadas al sol el ángulo cenital no coincide con el ángulo de incidencia, mientras en las opuestas puede ocurrir que no se reciba en absoluto energía solar directa (cuando la vertiente está en umbría). Si no se tiene en cuenta este efecto del relieve, la reflectividad medida para la misma cubierta en distintas vertientes puede ser muy variada, implicando severos problemas en el reconocimiento y clasificación de coberturas temáticas.

Una manera muy sencilla de eliminar el efecto topográfico sería realizar un simple cociente entre dos bandas de la misma imagen. Puesto que los ángulos de inciden-

cia son constantes entre bandas (el $\cos \theta_i$ en la fórmula [6.22]), cuando se realiza un cociente entre bandas adquiridas simultáneamente, este efecto se elimina. En definitiva, esto supone que el efecto de la topografía es constante en cada banda (Colby, 1991; Short, 1982), o, lo que es lo mismo, que los efectos atmosféricos son independientes de la longitud de onda (λ). Esto no es correcto, ya que hemos visto que la dispersión y transmisividad está en función de λ (Leprieur *et al.*, 1988). Además, al realizar el cociente se reduce la información espectral, lo que es un inconveniente para realizar la clasificación. Finalmente, tampoco se considera el aporte de luz difusa, que es distinto en cada banda.

Caso de que pueda disponerse de un MDE suficientemente preciso y bien ajustado a la imagen se puede estimar la variación introducida en los ND por el efecto topográfico a partir de modelar las condiciones de iluminación en el momento de adquirirse la imagen. Para ello necesitamos en primer lugar calcular el ángulo de incidencia (γ_i) de una vertiente, que depende de los ángulos solares y de pendiente (Civco, 1989; Colby, 1991; Conese *et al.*, 1993):

$$\cos \gamma_i = \cos \theta_i \cos \theta_p + \operatorname{sen} \theta_i \operatorname{sen} \theta_p \cos (\phi_a - \phi_o) \qquad [6.35]$$

donde γ_i corresponde al ángulo cenital del flujo incidente, θ_i indica el ángulo cenital solar, θ_p el gradiente de la pendiente, ϕ_a el ángulo acimutal solar y ϕ_o el ángulo de orientación de la pendiente. Estos cuatro ángulos pueden obtenerse del MDE y de la fecha y hora de adquisición de la imagen. El $\cos \gamma_i$ nos sirve para valorar el efecto de iluminación en la vertiente y es equivalente al sombreado que recogen numerosos programas SIG. Como es lógico, varía entre -1 y $+1$, indicando para cada píxel del MDE las condiciones de mínima y máxima iluminación, respectivamente. La figura 6.34 recoge un fragmento de la imagen Torrel00, en su sector más montañoso, junto con la imagen de iluminación ($\cos \gamma_i$) para la misma zona y condiciones de adquisición de la imagen. Las flechas indican en qué sectores resulta especialmente evidente el efecto del sombreado sobre la imagen original.

A partir de haber calculado el ángulo de incidencia pueden plantearse distintos

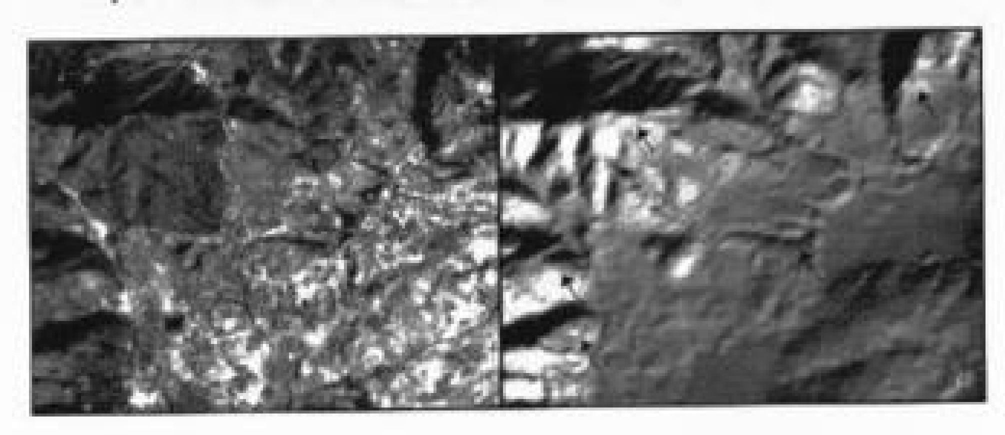


FIG. 6.34. *Ventana de la imagen Torrel00 sobre un sector montañoso: a) banda 4 original. b) sombreado derivado del MDE.*

métodos para compensar la diferencia de radiación incidente entre vertientes. Entre los propuestos cabe distinguir los que consideran las cubiertas como lambertianas, y las que tienen en cuenta efectos direccionales (Itten y Meyer, 1993; Riaño, 2000). Entre los primeros el más sencillo es el propuesto por Teillet (1982):

$$\rho_{h,i} = \rho_i \left(\frac{\cos \theta_i}{\cos \gamma_i} \right) \quad [6.36]$$

donde $\rho_{h,i}$ indica la reflectividad de un píxel i en terreno horizontal, ρ_i la misma en pendiente (la correspondiente a la imagen), θ_i el ángulo cenital solar de la escena y γ_i el ángulo de incidencia correspondiente a ese píxel. Este método se ha demostrado que sobre-corrige la imagen, sobre todo en las zonas de muy baja iluminación (Duguay y LeDrew, 1992; Holben y Justice, 1981; Meyer *et al.*, 1993), por lo que se ha propuesto posteriormente ponderar la imagen de iluminación en función de las condiciones promedio de iluminación de la imagen (Civco, 1989):

$$\rho_{h,i} = \rho_i + \rho_i \frac{(\cos \gamma_m - \cos \gamma_i)}{(\cos \gamma_m)} \quad [6.37]$$

donde el subíndice m indicaría el valor promedio de la iluminación en la imagen de interés.

Este modelo reduce el efecto topográfico, aunque no todo lo que debiera. Tanto en esta corrección como en la anterior se sigue suponiendo que el efecto topográfico es constante para todas las bandas.

Entre los métodos no lambertianos, uno de los más citados es el propuesto por Minnaert para evaluar la rugosidad de la superficie lunar (Minnaert, 1941):

$$\rho_{h,i} = \rho_i \left(\frac{\cos \theta_i}{\cos \gamma_i} \right)^l \quad [6.38]$$

donde el parámetro l se introduce para modelar el comportamiento no lambertiano de los cuerpos. Si $l = 1$, la superficie se comporta como un reflector lambertiano ideal. El problema de este método es conseguir un cálculo certero de l, ya que varía en cada banda y cada superficie. Una manera sencilla de tener en cuenta, al menos, la importancia del carácter lambertiano en cada banda es realizar un ajuste semi-empírico como el propuesto en la corrección C (Teillet *et al.*, 1982):

$$\rho_{h,i} = \rho_i \left(\frac{\cos \theta_i + c_k}{\cos \gamma_i + c_k} \right) \quad [6.39]$$

donde c_k es una constante empírica para cada banda k que se relaciona con la rugosidad promedio de esa banda, y se obtiene a partir de:

$$c_k = \left(\frac{b_k}{m_k} \right) \quad [6.40]$$

siendo b_k y m_k la constante y la pendiente, respectivamente, de la recta de regresión entre la imagen de reflectividad de la banda k y la imagen de iluminación.

El problema de estas correcciones sencillas es la falta de consideración de la irradiancia difusa, que puede ser importante en las vertientes situadas a umbría. Se han propuesto algunas alternativas para resolver ese problema, pero resultan más complicadas en su aplicación práctica. Por ejemplo, Conese *et al.* (1993) proponen utilizar una variación de la fórmula para la radiancia incidente que considere los efectos de la pendiente:

$$E^*_{m,k} = E_{0,k} \cos \gamma_i \tau_{k,i} + E^*_{d,k} \quad [6.41]$$

donde $E^*_{m,k}$ y $E^*_{d,k}$ indican la radiancia que llega al suelo y la difusa, respectivamente, en un terreno montañoso. Si el ángulo de incidencia (γ_i) supera los 90° (o, si se prefiere, el $\cos \gamma < 0$), la vertiente está en sombra. No hay, por tanto, iluminación directa, y la que llega al suelo es únicamente la difusa ($E^*_{d,k}$), que se calcula a partir de las condiciones atmosféricas en función del ángulo de incidencia, de la pendiente del terreno y de un coeficiente de anisotropía ($E_{m,k} / E_{0,k}$), dependiente de la banda y la fecha de observación. Para el ámbito de trabajo presentado por estos autores, esta corrección topográfica mejora bastante el cálculo de reflectividades en zonas de topografía quebrada, reduciendo notablemente la variabilidad espectral de los tipos de cubierta. No obstante, los autores advierten que el algoritmo resulta poco adecuado para imágenes de invierno o topografía muy abrupta, con ángulos de incidencia muy bajos (Conese *et al.*, 1993). Esta misma conclusión se manifiesta por otros autores que han propuesto métodos más o menos similares para el cálculo de la irradiancia difusa (Itten y Meyer, 1993; Richter, 1997).

Un ejemplo del efecto de las correcciones topográficas sobre nuestra zona de estudio se presenta en la figura 6.35, que incluye la misma zona de la figura anterior. En

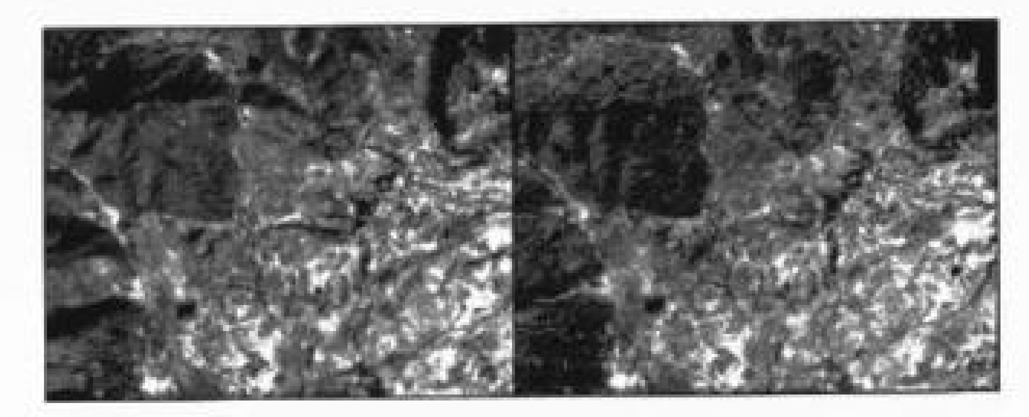


FIG. 6.35. *Efecto de la corrección del sombreado sobre el sector de la figura anterior: a) banda 4 original; b) banda 4 corregida.*

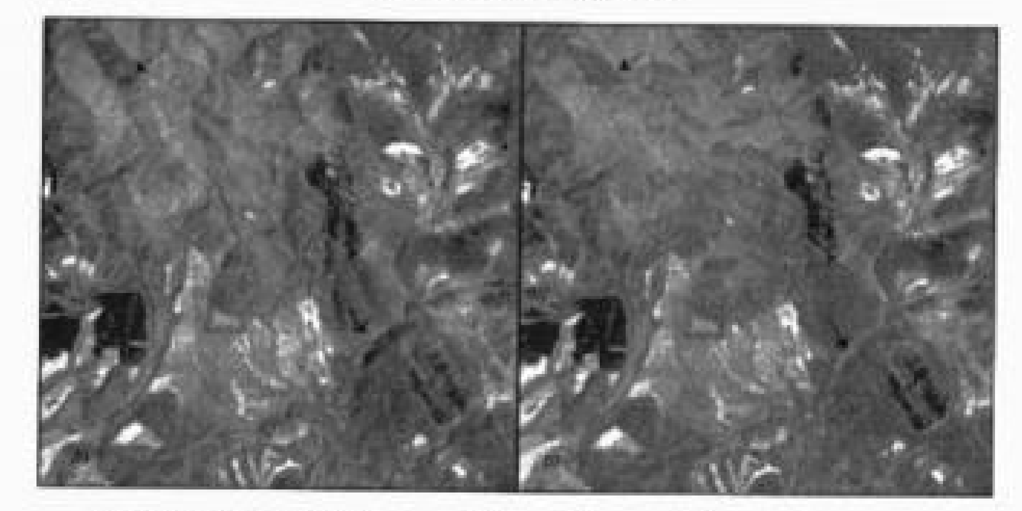


FIG. 6.36. *Fragmento de la imagen Cabañeros97 antes a) y después b) de aplicarle la corrección de iluminación. Con flechas se indican los sectores más afectados.* (Cortesía: David Riaño.)

este caso se compara la banda 4 antes y después de aplicarle la corrección de iluminación, utilizando el método de Civco que, para esta fecha, da buenos resultados. Las flechas indican los sectores donde el efecto de corrección resulta más evidente. Una manera de verificar el efecto de la corrección es calcular la correlación entre la imagen de iluminación y las bandas de la imagen, antes y después de corregir. Para nuestra zona de estudio, la correlación disminuye tras la corrección de 0,18 a 0,13 en la banda 4 y de 0,25 a 0,14 en la 5, indicando que se ha eliminado parte del efecto topográfico sobre la señal. Otra verificación nos llevaría a medir las diferencias de reflectividad en una serie de cubiertas situadas a distintas vertientes. Si la corrección es certera, deberían homogeneizarse los valores, eliminando sus diferencias debidas a la insolación. Esta hipótesis se comprobó por Riaño (2000) en su estudio sobre cartografía de combustibles forestales en el Parque Nacional de Cabañeros. Las correcciones topográficas redujeron la desviación típica de la mayor parte de las especies vegetales, con especial intensidad en las bandas TM 4 y 5. La figura 6.36 nos muestra el efecto de la corrección sobre imágenes TM de julio de 1997. De nuevo, las flechas nos indican los sectores más claramente modificados por la corrección.

6.2.3.4. Corrección del efecto bidireccional (BRDF)

El último aspecto que vamos a considerar en el cálculo de la reflectividad hace referencia al efecto que los ángulos de observación y de iluminación tienen sobre la reflectividad detectada por el sensor. Como ya hemos comentado a lo largo de las páginas precedentes es frecuente asumir en los modelos para el cálculo de reflectividad que una cubierta presenta un comportamiento lambertiano, lo que implica considerar que la radiancia reflejada por esa cubierta sea igual en todas las direcciones. Esta asunción es razonable como primera aproximación al cálculo de la reflectividad, pero dista bastante de ser correcta. Todos tenemos la experiencia directa de cómo cambia la visión de un objeto según se sitúe el observador en relación con la luz incidente (fig. 6.37), por lo que parece razonable tener en cuenta este factor en cálculos más detallados de la reflectividad.

Hasta hace relativamente poco, la mayor parte de los sensores ofrecían únicamente visión vertical, por lo que se asumía que la señal que medían eran comparable en el tiempo (lógicamente con las variaciones atmosféricas y de iluminación pertinentes). Sin embargo, en el caso de otros sensores de ángulos más amplios de barrido, como los meteorológicos, las zonas observadas podían variar no sólo por estos factores, sino también por la variación en las condiciones de iluminación y de observación. En otras palabras, cuando las observaciones no se realizan con los mismos ángulos (solares y del sensor), no son perfectamente comparables, por lo que las series temporales pueden ser bastante inconsistentes. En el caso del AVHRR, uno de los sensores más utilizados en análisis temporal de la vegetación, este factor tendía a paliarse mediante métodos que eligieran, dentro de una serie de imágenes diarias, aquellos píxeles más cercanos a una visión vertical, pero esto no siempre se garantiza por el problema de la cobertura de nubes. En consecuencia, si quieren utilizarse las series diarias es preciso introducir algún tipo de corrección del efecto direccional.

Para abordar estas correcciones se utilizan las llamadas funciones de distribución de reflectividad bidireccional (BRDF, *Bidirectional Reflectance Distribution Factor*). Se trata éste de un concepto teórico, que describe los efectos direccionales de la reflectividad comparando la radiancia reflejada en una determinada dirección con la incidente en otra (Sandmeier e Itten, 1999):

$$f(\theta_i, \phi_i; \theta_r, \phi_r, \lambda) = \frac{dL(\theta_r, \phi_r, \lambda)}{dE(\theta_i, \phi_i, \lambda)} \qquad [6.42]$$



FIG. 6.37. *Variaciones en la reflectividad de una cubierta forestal por efecto de los ángulos de observación. En la foto de la izqda., el sol está detrás de la cámara; en la dcha., delante.* (Tomado de http://crsa.bu.edu/~nstrug/brdf/BRDF Explained.htm)

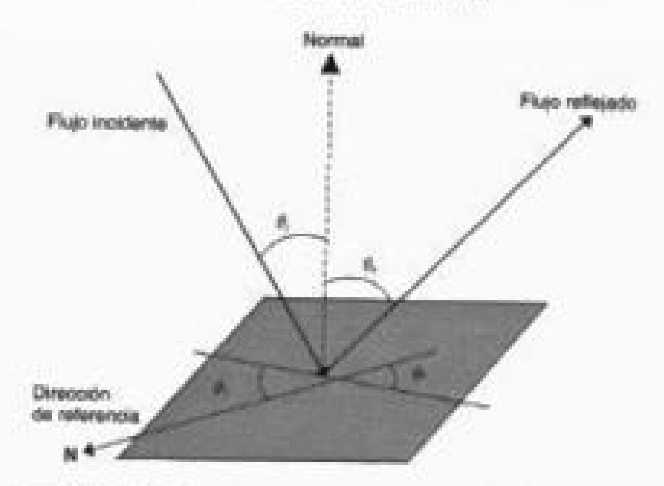


FIG. 6.38. *Ángulos que intervienen en el cálculo de la BRDF.*

donde dL es la radiancia reflejada con un determinado ángulo cenital (θ_r) y acimutal (ϕ_r) y dE la irradiancia incidente con una determinada dirección: cenital (θ_i) y acimutal (ϕ_i) (fig. 6.38). Le hemos añadido el parámetro λ para indicar que la BRDF es también dependiente de la longitud de onda, o, lo que es lo mismo, que las diferencias debidas a las direcciones de observación no van a afectar por igual a las distintas bandas del espectro, siendo más severos los efectos direccionales en las longitudes más cortas (principalmente en el azul y rojo para el caso de la vegetación: Sandmeier e Itten, 1999). A veces puede resultar más gráfico que la función BRDF el denominado factor de anisotropía (ANIF), que relaciona la reflectividad de un cubierta en una dirección determinada con la que se obtendría para una dirección de referencia (normalmente, para una observación vertical):

$$\mathrm{ANIF}(\theta_i, \phi_i; \theta_r, \phi_r, \lambda) = \frac{R(\theta_r, \phi_r, \lambda)}{R_o(\theta_i, \phi_i, \lambda)} \qquad [6.43]$$

Estos factores son de gran interés para conocer mejor el comportamiento direccional de una determinada cubierta. Nos permitirían estandarizar las reflectividades observadas a una base común, siempre que conozcamos los ángulos solares y de situación del sensor. Algunos ejemplos de estos gráficos se incluyen en la fig. 6.39 para el caso concreto de una cubierta herbácea. Se observa que la misma cubierta presenta efectos direccionales muy distintos según la longitud de onda. En las bandas de fuerte absorción (azul y rojo), esta cubierta tiende a ofrecer un claro componente direccional, con mayores intensidades hacia ángulos próximos a la vertical y cuando se observa de espaldas al sol. Por su parte, el IRC y, en menor medida, el verde tienen un efecto direccional menos marcado.

Para poder introducir estas correcciones en las imágenes necesitamos información sobre el carácter iso o anisotrópico de las cubiertas que observamos, en definitiva contar con sus BRDF. Esta información no es fácilmente accesible, ya que hasta hace relativamente poco no se contaba con sensores de observación multiangular. La mayor parte de los estudios disponibles se basan en goniómetros de campo (Sandmeier e

FIG. 6.39. *Gráficos de anisotropía calculados a partir de las medidas radiométricas realizadas con un goniómetro de campo sobre una cubierta herbácea.* (Sandmeier e Itten, 1999.)

Itten, 1999), si bien se están construyendo actualmente estas funciones a partir de algunos sensores más modernos (como el MISR o el POLDER). Conocer el BRDF de una cubierta, no sólo servirá para mejorar su discriminación, eliminando la parte de la señal que proceda de los ángulos de observación, sino que en sí mismo será una variable más que permita introducir discriminaciones más sutiles (por ejemplo, debidas a efectos de sombra en determinadas especies forestales). De ahí el interés por enriquecer la signatura espectral de una determinada cubierta añadiendo también lo que podríamos llamar su «signatura angular», o mejor aún las variaciones angulares de las signaturas espectrales. Este enfoque se ha desarrollado hasta el momento con sensores aeroportados (Sandmeier y Deering, 1999).

A efectos prácticos es difícil introducir este parámetro en los cálculos de reflectividad, ya que la BRDF depende del tipo de cubierta que estemos observando, la cual será habitualmente desconocida en una primera interpretación. Para el caso de las imágenes AVHRR se ha propuesto una corrección relativamente sencilla, basada en un modelo físico de transferencia radiativa denominado WAK (Dymond *et al.*, 2001). Este modelo permite estimar un factor de estandarización de la reflectividad, suponiendo una orientación de referencia (visión vertical y 45° de ángulo cenital solar). En definitiva, se trata de encontrar un parámetro φ que permita convertir la reflectividad observada (ρ) en otra de referencia ($\hat{\rho}$):

$$\hat{\rho} = \varphi \rho \qquad [6.44]$$

El factor φ se calcula de forma distinta para el *R* e *IRC* del AVHRR (bandas 1 y 2, respectivamente). Los autores del método proponen (Shepherd y Dymond, 2000):

$$\varphi_R = \frac{\cos\theta_i + \cos\theta_r}{\cos\theta_{ir} + \cos\theta_{rr}} \left[\frac{a + (\pi - a)e^{-k\alpha_r^2}}{a + (\pi - a)e^{-k\alpha^2}} \right] \qquad [6.45]$$

y

$$\varphi_{IRC} = \frac{\cos\theta_i + \cos\theta_r}{\cos\theta_{ir} + \cos\theta_{rr}} \left[\frac{\frac{8}{3\pi}(a + (\pi - a)e^{-k\alpha_r^2}) + H(\theta_{rr}, w)H(\theta_{ir}, w) - 1}{\frac{8}{3\pi}(a + (\pi - a)e^{-k\alpha^2}) + H(\theta_i, w)H(\theta_r, w) - 1} \right] \qquad [6.46]$$

donde θ_i y θ_r indican los ángulos de incidencia y reflexión para la señal a corregir; θ_{ir} y θ_{rr} los correspondientes a la visión de referencia (habitualmente 45° y 0°, respectivamente). α y α_r son los ángulos de fase (los que forman los rayos del sol con la posición del sensor, esto es la diferencia de acimut entre el sol y el satélite) de la señal a corregir y de la visión de referencia (en este caso 45°). El término *H* considera las reflexiones múltiples en el interior del dosel vegetal y puede calcularse como:

$$H(\theta, w) = \frac{1 + 2\cos\theta}{1 + 2\cos\theta\sqrt{1 - w}} \qquad [6.47]$$

para cada uno de los ángulos considerados (incidencia, reflexión, tanto de la señal detectada como de la de referencia). El resto de los parámetros: w, α, k son dependientes de la cubierta observada y se calculan a partir de su BRDF. Si no está disponible, w pueden estimarse a partir de la reflectividad de la hoja (ρ; $w = 2\rho$), y α, k de un análisis de regresión a partir de datos procedentes de dos órbitas distintas del AVHRR sobre las misma zona (en definitiva, tomadas con ángulos distintos), minimizando los residuales (R_i) de la siguiente expresión:

$$\frac{\rho_a}{\rho_b} - \frac{\cos\theta_{ia} + \cos\theta_{ra}}{\cos\theta_{ib} + \cos\theta_{rb}} \left[\frac{a + (\pi - a)e^{-k\alpha_a^2}}{a + (\pi - a)e^{-k\alpha_b^2}} \right] = R_i \qquad [6.48]$$

donde ρ_a y ρ_b indican las reflectividades de una determinada cubierta extraídas de dos imágenes AVHRR (*a* y *b*) tomadas con distintos ángulos.

La figura 6.40 ofrece un ejemplo de la importancia de estos efectos direccionales en las imágenes AVHRR. Incluye una serie de valores de reflectividad para las bandas 1 y 2 extraídos de un sector de pinares en la provincia de Cuenca, así como los ángulos solares en el momento de la adquisición. Todas ellas son imágenes de la pasada diurna del NOAA-16 adquiridas entre las 13 y las 14,22 GMT. La dependencia del ángulo acimutal solar es bastante clara, observándose una tendencia cíclica en la reflectividad que se relaciona estrechamente con el ciclo orbital del satélite.

6.2.4. *Cálculo de temperaturas*

El cálculo de la temperatura de superficie es un proceso rutinario en aplicaciones oceanográficas, en donde este parámetro es clave para estudiar aspectos climáticos, así

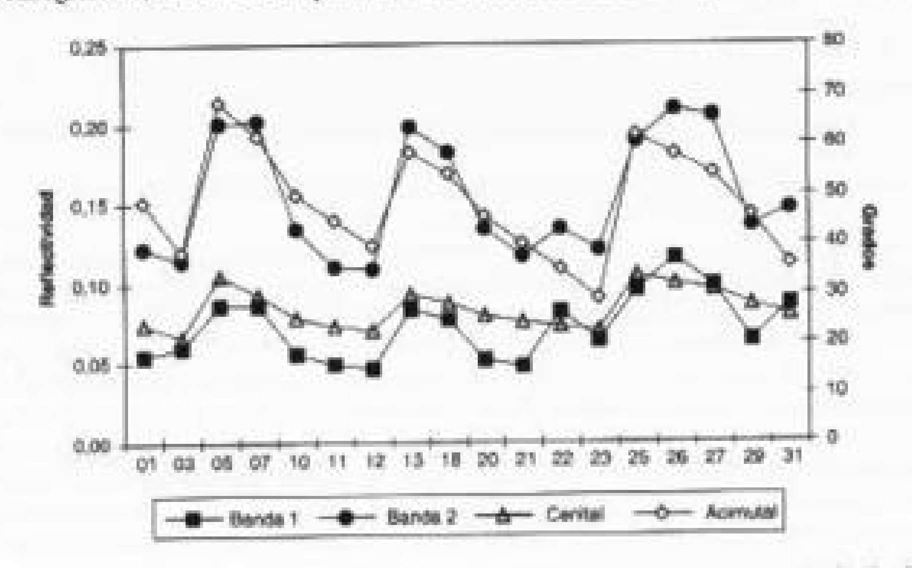


FIG. 6.40. *Serie temporal de valores de reflectividad extraídos a partir de los canales 1 y 2 del AVHRR en julio de 2001. Se incluyen los ángulos acimutal y cenital solar para observar el efecto que tienen sobre la señal detectada por el sensor.*

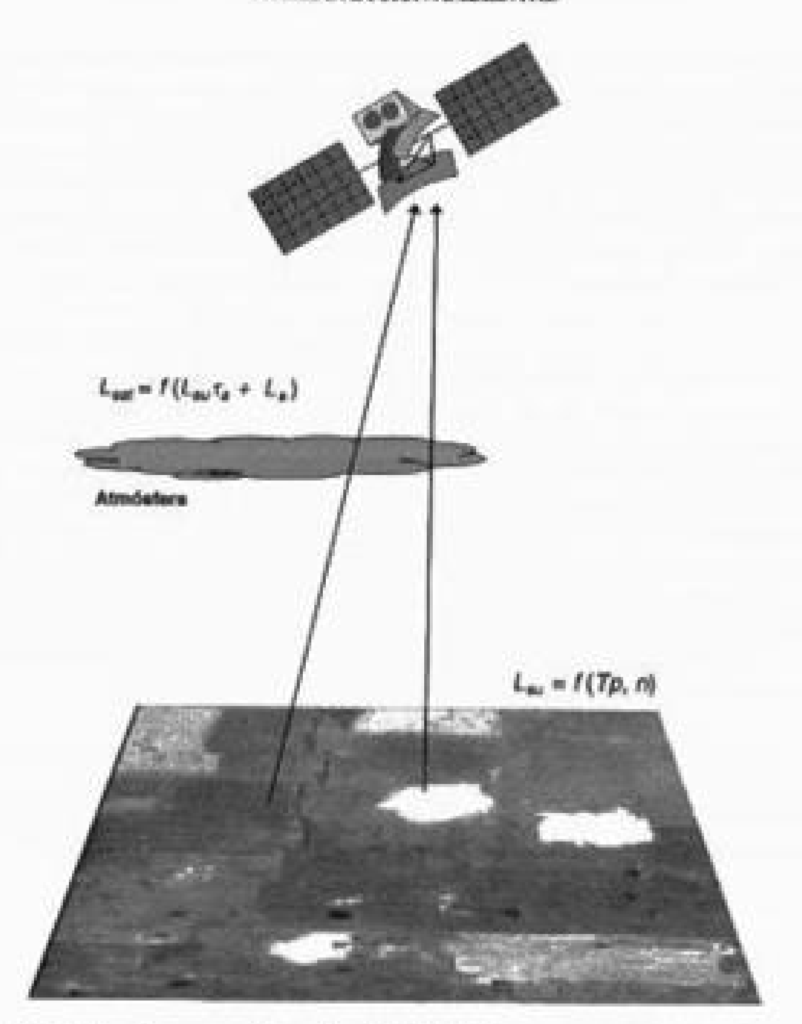


FIG. 6.41. *Esquema gráfico sobre el cálculo de la temperatura de superficie.*

como en aplicaciones pesqueras. En lo que se refiere a temperaturas terrestres, la investigación ha sido muy intensa en los últimos años, ya que, pese a la dificultad de la estimación, se considera un elemento clave en los estudios de cambio climático global.

De modo esquemático (fig. 6.41), el proceso para el cálculo de temperatura se inicia con los ND detectados por el sensor. Al igual que en el espectro óptico, esos valores codifican un valor de radiancia, en este caso correspondiente al infrarrojo térmico. Aquí el objetivo no es encontrar la relación entre el flujo incidente en el suelo y el reflejado al sensor, sino entre el flujo emitido desde el suelo (L_{su}) y el recibido por el sensor (L_{sen}). Entre ambas magnitudes vuelven a interponerse los componentes de la atmósfera, que absorben y emiten su propia energía, distorsionando la radiancia recibida por el sensor.

Supuesto que eliminásemos las influencias atmosféricas, bastaría conocer el flujo emitido en el suelo para saber su temperatura, ya que, como vimos, la radiación que

emite un objeto es una función de su temperatura, de acuerdo a la ley de Planck [2.4]. Ahora bien, esta ley está definida para cuerpos negros. En consecuencia, el segundo problema en el cálculo de la temperatura radiativa, y además el más espinoso, es estimar la relación entre la emitancia de una superficie determinada y la que se produce en un cuerpo negro a la misma temperatura; en definitiva, es preciso conocer la emisividad de la cubierta para calcular su temperatura.

Tras este comentario podemos ofrecer un esquema más cuantitativo para abordar ese cálculo. Seguimos el método propuesto por Coll *et al.* (1994), refinado por Caselles *et al.* (1995) para obtener temperaturas de superficie *(TS)* a partir de imágenes AVHRR. Aunque también puede calcularse la *TS* desde imágenes Landsat-TM (que cuenta con una sola banda térmica), el sensor AVHRR ha sido el más utilizado para este tipo de estudios, ya que son más convenientes sus horas de adquisición.[6] El método propuesto en este epígrafe está ajustado a latitudes medias, en donde los autores han encontrado errores por debajo de 1,1 K para la determinación de la temperatura superficial del suelo y de 0,7 K para la superficie del mar (Caselles *et al.*, 1995).

Al igual que en el caso de las reflectividades, el primer paso en el cálculo de la temperatura es convertir los ND en radiancias. Puede usarse la misma fórmula antes vista [6.22], si bien en este caso los coeficientes se cambian de línea a línea, aunque de modo poco significativo, de acuerdo al sistema de calibración que utiliza el AVHRR para sus dos bandas térmicas.

Una vez calculada la radiancia, puede estimarse la temperatura de brillo a partir de la inversión de la ecuación de Planck (Kidwell, 1991):

$$T^{*}(L) = \frac{c_2 v}{\ln(1 + c_1 v^3 / L_{sen,i})} \qquad [6.49]$$

donde T^{*} indica la temperatura de brillo en Kelvin para un determinado valor de radiancia L, v corresponde a la longitud de onda central de la banda térmica que estemos considerando (cm^{-1}), y c_1 y c_2 son constantes ($c_1 = 1{,}1910659 \times 10^{-5}$ mW m^{-2} sr^{-1} cm^{-4} y $c_2 = 1{,}438833$ cm K).

Para esta región del espectro, numerosos autores han sugerido basar la corrección atmosférica en los datos de la propia imagen. En este caso se utilizan las diferencias de temperatura medidas en dos bandas cercanas del térmico para estimar la transmisividad atmosférica. Estos métodos se conocen con el nombre genérico de algoritmos de ventana partida *(split window)*, puesto que se necesita contar al menos con dos bandas en la ventana del IRT. La fórmula genérica de este tipo de correcciones sería:

$$T_s = T^{*}_i + A(T^{*}_i - T^{*}_j) - B \qquad [6.50]$$

siendo T_s la temperatura del suelo, y T^{*}_i y T^{*}_j las temperaturas de brillo en dos bandas contiguas del espectro. A y B son coeficientes dependientes del tipo de atmósfera. Otros autores han propuesto formulaciones similares para la observación biangular.

6. En los últimos años también cabe destacar los análisis de temperaturas de superficie a partir del ATSR (Sobrino, 2000) o del MODIS (http://modis.gsfc.nasa.gov/MODIS/modis_front.html).

esto es la adquisición de la misma banda del IRT pero con dos ángulos distintos, como ocurre con el ATSR (Sobrino, 2000).

Sin embargo, son más habituales las ecuaciones basadas en el algoritmo antes mencionado [6.50], ya que el sensor AVHRR ha sido la principal fuente de datos para obtener temperaturas de superficie en las últimas décadas. Para las condiciones promedio de nuestras latitudes podemos utilizar los coeficientes propuestos por Caselles y colaboradores (Caselles *et al.*, 1995; Coll *et al.*, 1994) para la corrección atmosférica:

$$T^*_s = T^*_4 + [1{,}0 + 0{,}58\,(T^*_4 - T^*_5)]\,(T^*_4 - T^*_5) \qquad [6.51]$$

donde T^*_s indica la temperatura de brillo en la superficie; T^*_4 y T^*_5 son respectivamente las temperaturas de brillo de las bandas 4 y 5 del AVHRR.

El último paso para obtener la temperatura de superficie sería introducir la corrección de emisividad, que valora la eficiencia radiativa de una determinada superficie. La importancia de este factor se incorpora en la siguiente fórmula:

$$T_s = T^*_s + 0{,}51 + 40\,(1 - \bar{\varepsilon}) - 75\,\Delta\varepsilon \qquad [6.52]$$

donde $\bar{\varepsilon}$ corresponde a la emisividad promedio de un píxel en las bandas 4 y 5 del AVHRR, y $\Delta\varepsilon$ a la diferencia de emisividad para el mismo píxel en esas dos bandas ($\Delta\varepsilon = \varepsilon_4 - \varepsilon_5$).

El problema más complejo a resolver aquí sería la estimación de la emisividad de la superficie terrestre, pues no es derivable directamente de los datos térmicos. La emisividad depende del tipo de cubierta que esté observando el sensor, lo que frecuentemente no nos es conocido. Incluso cuando tengamos acceso a un mapa de cobertura del suelo de la zona observada, la estimación de la emisividad puede no ser muy correcta, por un lado por la variación estacional de las cubiertas vegetales (por ejemplo, una zona de cultivos aparecerá como suelo descubierto en algunos períodos del año), y por otro, por la propia heterogeneidad del píxel, ya que aproximadamente en 1 km^2 (la mejor resolución espacial del AVHRR) puede haber una mezcla notable de tipos de cobertura y, por tanto, de emisividades. Lógicamente, esto no ocurre en la determinación de la temperatura del océano, en donde la emisividad es fácilmente calculable.

Una manera sencilla de estimar la emisividad para zonas no marinas sería asumir que un píxel está formado únicamente por suelo o vegetación, calculando una emisividad promedio en función de la proporción de superficie ocupada por estas dos cubiertas. Para estimar estas proporciones, Valor y Caselles (1996) sugirieron un método basado en los datos de la propia imagen, más concretamente en las bandas del *R* e *IRC*, a partir de los cuales se pueden calcular índices de verdor (como veremos más adelante: 7.1.2). De acuerdo a este método, la proporción del píxel ocupado por vegetación puede obtenerse a partir de la relación entre su índice de vegetación (NDVI) y los mínimos y máximos de verdor detectados en una serie suficientemente larga de imágenes:

$$P_v = \frac{(1 - (NDVI / NDVI_{min}))}{(1 - (NDVI / NDVI_{min})) - k(1 - (NDVI / NDVI_{max}))} \qquad [6.53]$$



FIG. 1*. *Imágenes Ikonos del sur de Manhattan tomadas antes y poco después del atentado del 11 de septiembre de 2001.* Estas imágenes se publicaron en varios medios de comunicación para ilustrar la noticia. (Cortesía: *Space Imaging*.)

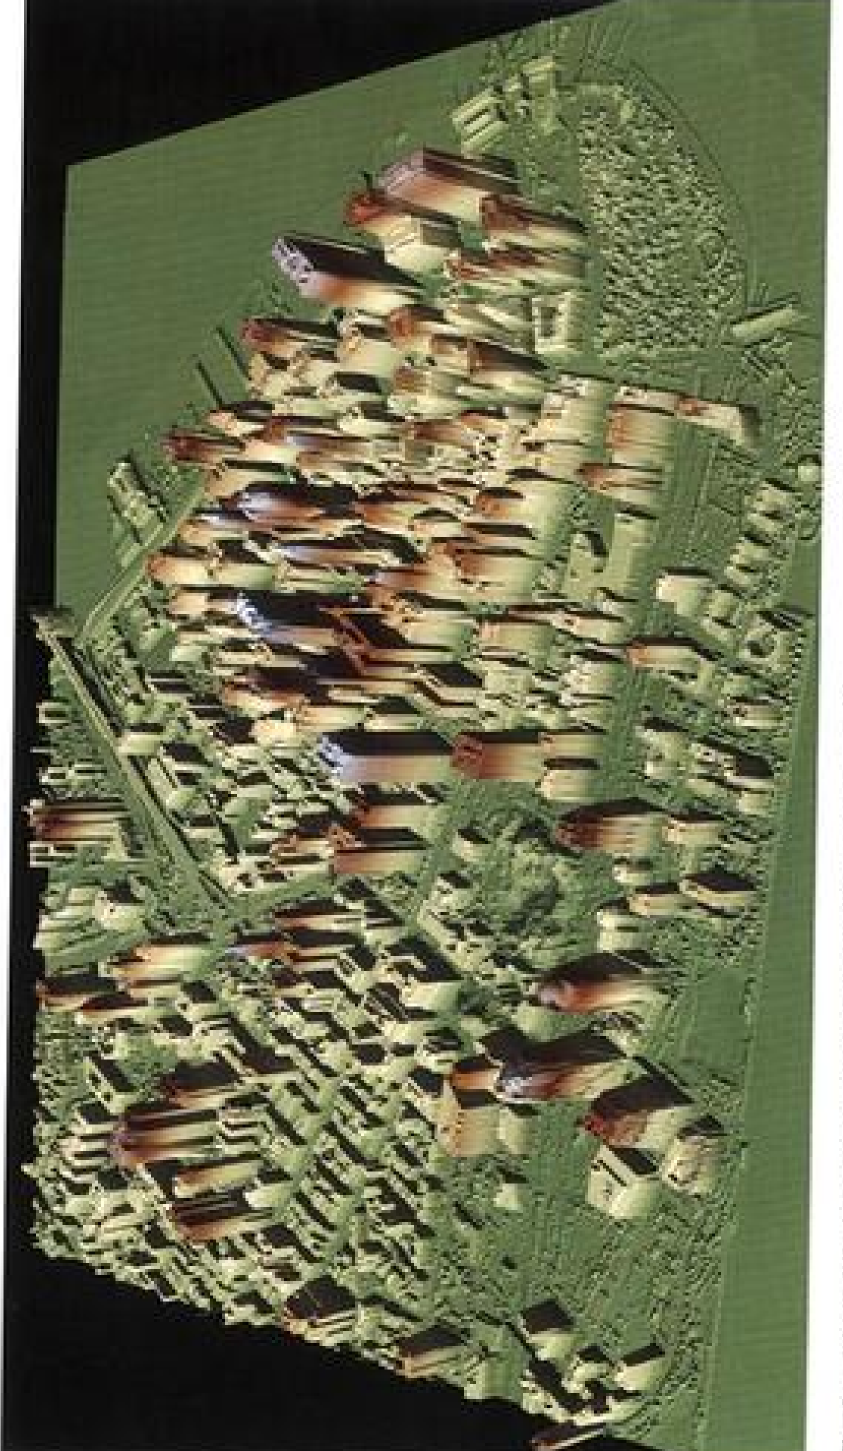


Fig. 2*. *Reconstrucción de alturas en la isla de Manhattan a partir de un lidar aerotransportado El vuelo se realizó el 23 de septiembre de 2001.*
(Cortesía: NOAA/U.S.Army JPSD, www.noaa.gov.)

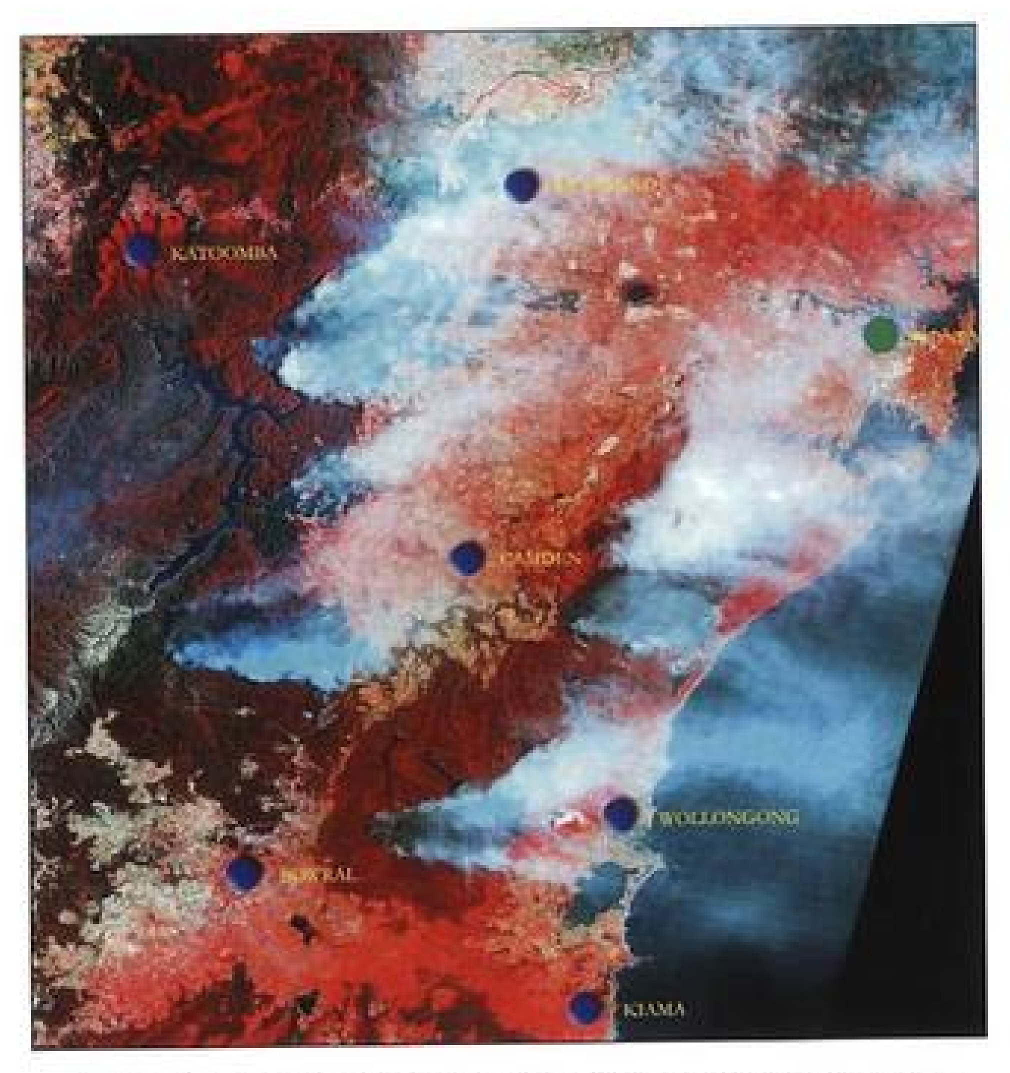


Fig. 3*. *Mosaico de imágenes SPOT adquiridas el 27 de diciembre de 2001 mostrando un amplio frente de incendios activos en el suroeste de Australia. Se observa nítidamente el efecto de absorción de los aerosoles producidos por el fuego.*
(ACRES, Geoscience Australia. © CNES 2001).

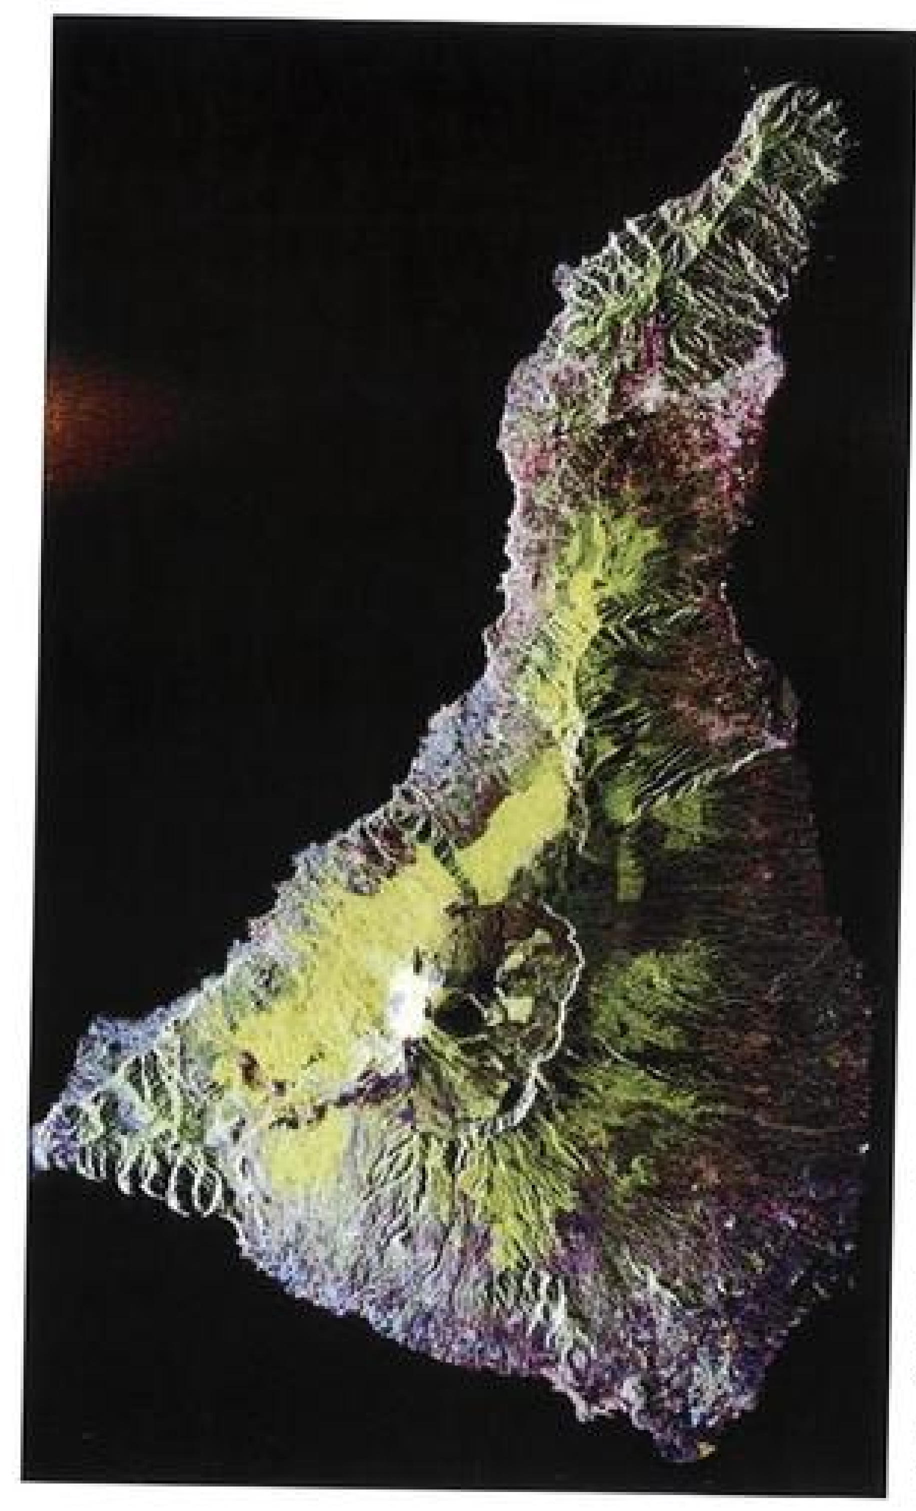


FIG. 4*. *Composición en color de una imagen radar de la isla de Tenerife, correspondiente a la misión SIR-C/X-SAR del Endeavour (11/X/1994).* En rojo aparece la banda L (polarización HH); en verde la banda L (polarización HV), y en azul la banda C (polarización HV). (Cortesía: NASA, http://visibleearth.nasa.gov.)

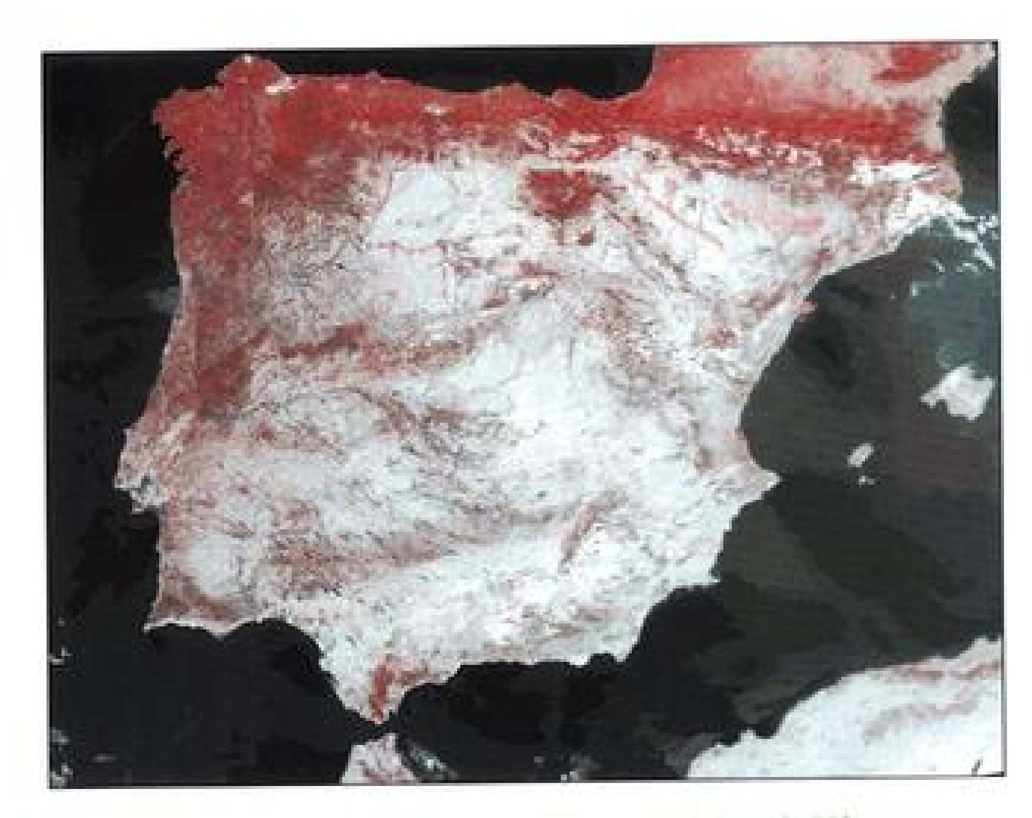


FIG. 5*. *Imagen NOAA-AVHRR de la península Ibérica adquirida por la antena HRPT instalada en el Departamento de Geografía (Universidad de Alcalá).*

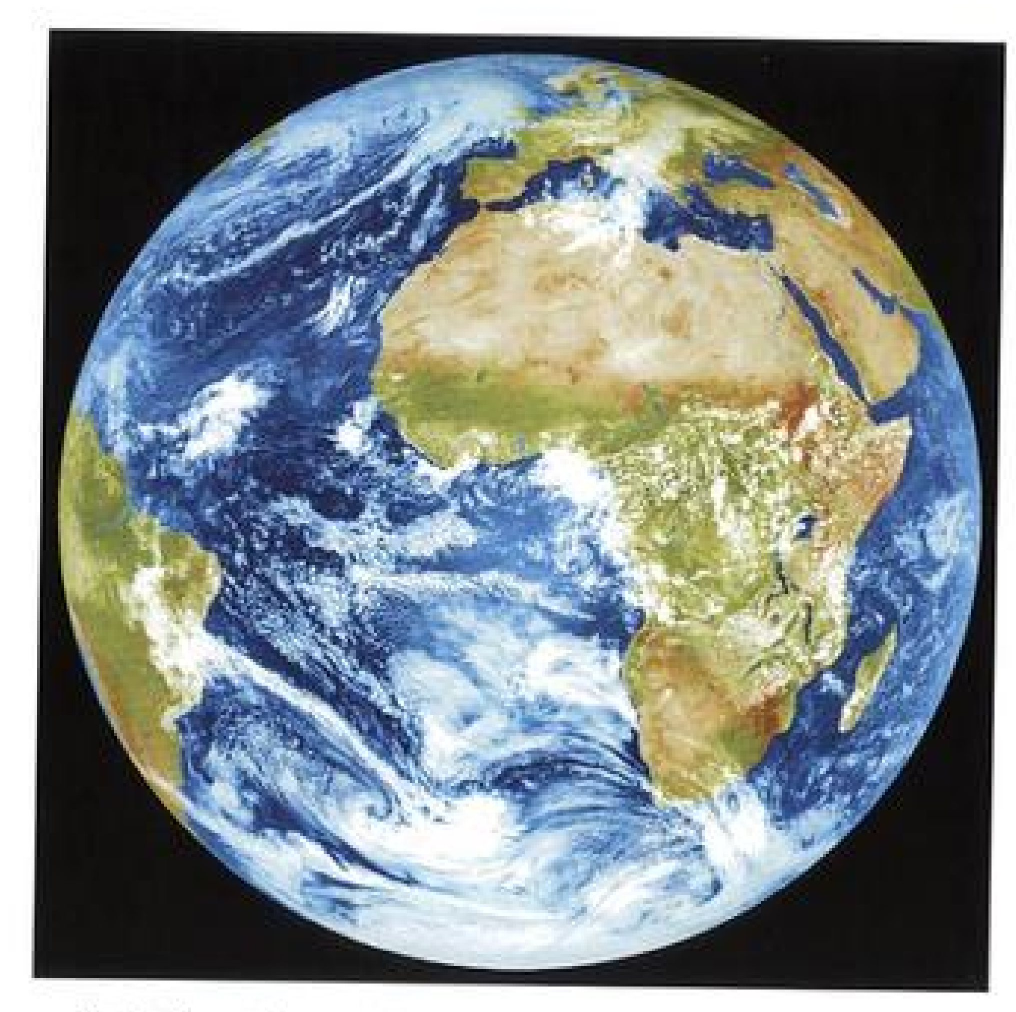


Fig. 6*. *Imagen Meteosat del disco visible de la Tierra adquirida en octubre de 1998.* (Cortesía: EUMETSAT.)



Fig. 7*. *Imagen Aster del Estrecho de Gibraltar adquirida el 5 de julio de 2000.* (Cortesía: NASA, http://visibleearth.nasa.gov.)



FIG. 8*. *Imagen Modis del Cono Sur adquirida el 24 de Abril de 2000. Composición en color real de los canales reflectivos.* (Cortesía: NASA. http://visibleearth.nasa.gov.)



FIG. 9*. *Altura media de la superficie marina generada a partir de datos del ERS-1.* (Cortesía: Agencia Espacial Europea.)

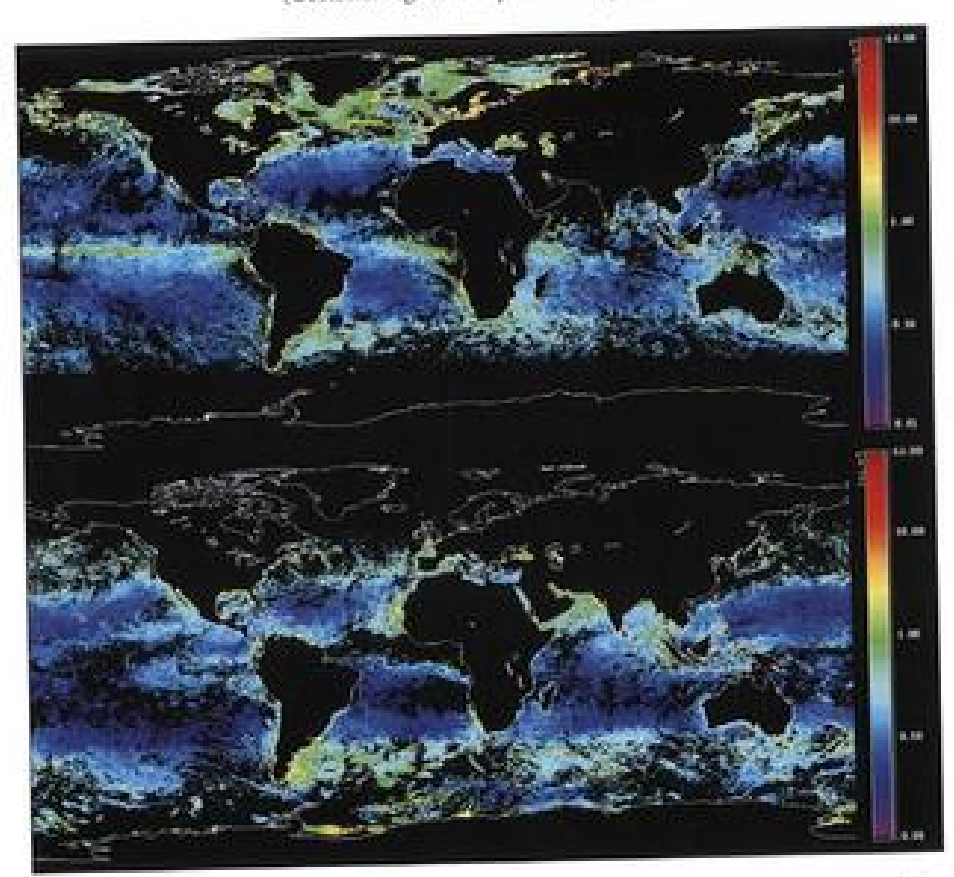


FIG. 10*. *Imágenes del contenido de clorofila en el agua para los meses de enero (arriba) y junio (abajo) calculadas a partir de datos Seawifs.* (Cortesía: Orbimage.)

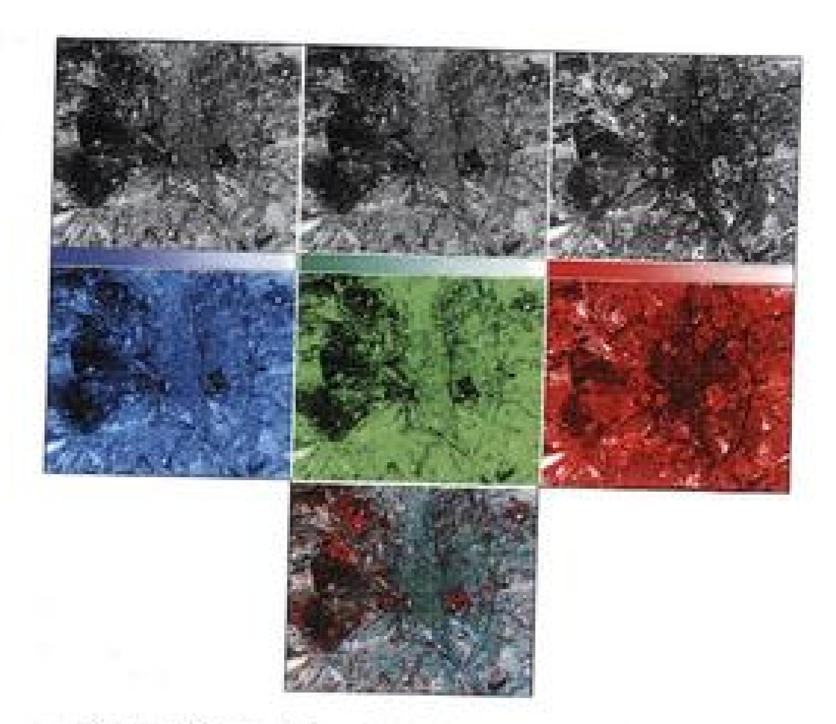


FIG. 11*. *Proceso de formación de las composiciones coloreadas.*

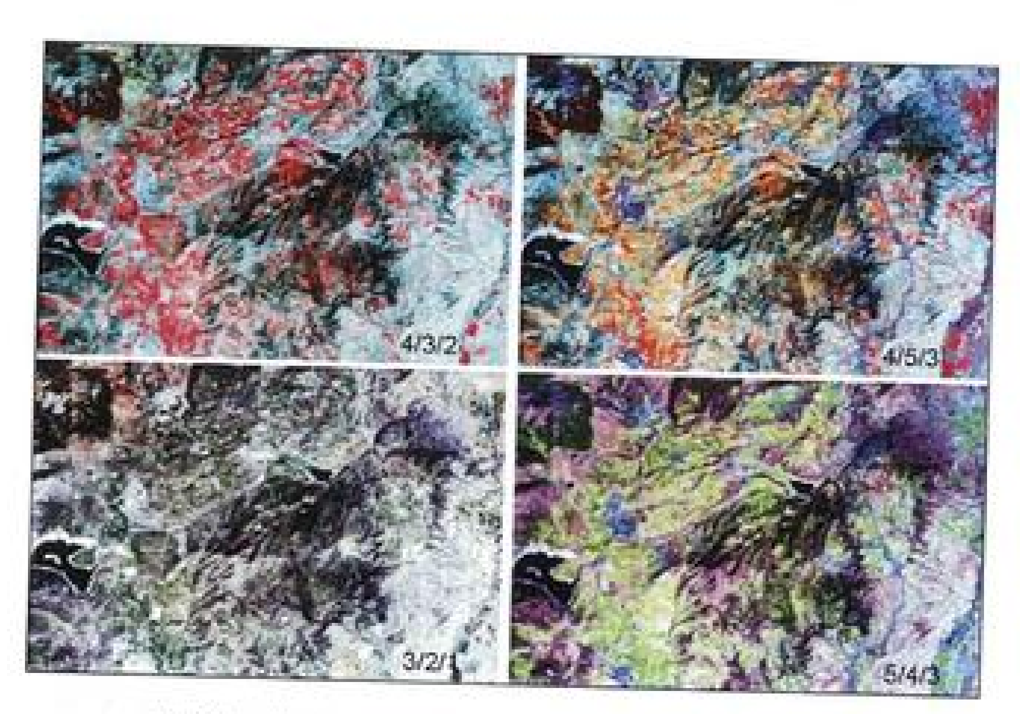


FIG. 12*. *Diversas composiciones en color sobre la imagen Torrel00.*

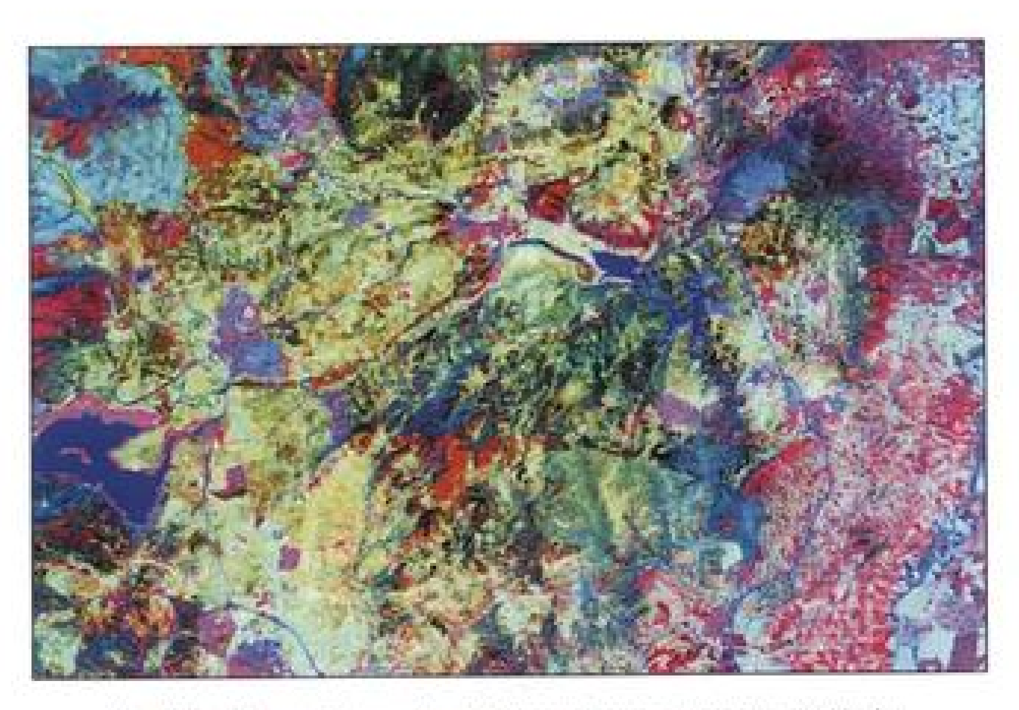


FIG. 13*. *Composición en color de los tres primeros componentes principales (rojo, verde y azul, respectivamente).*

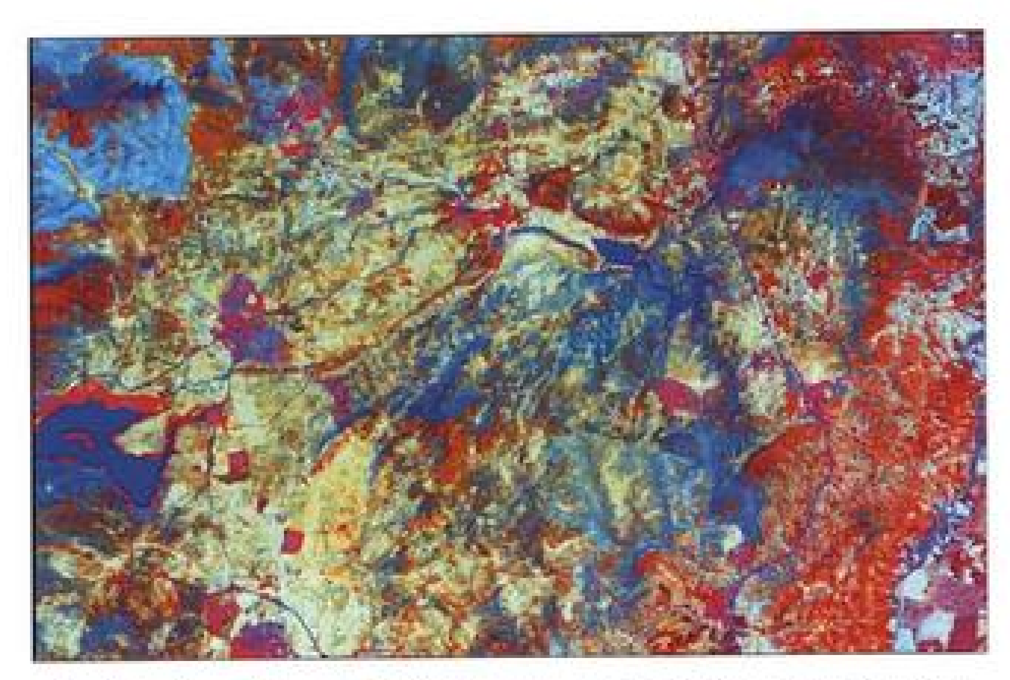


FIG. 14*. *Composición en color de los tres componentes* Tasseled Cap*: En azul, humedad; en rojo, brillo; en verde, verdor.*

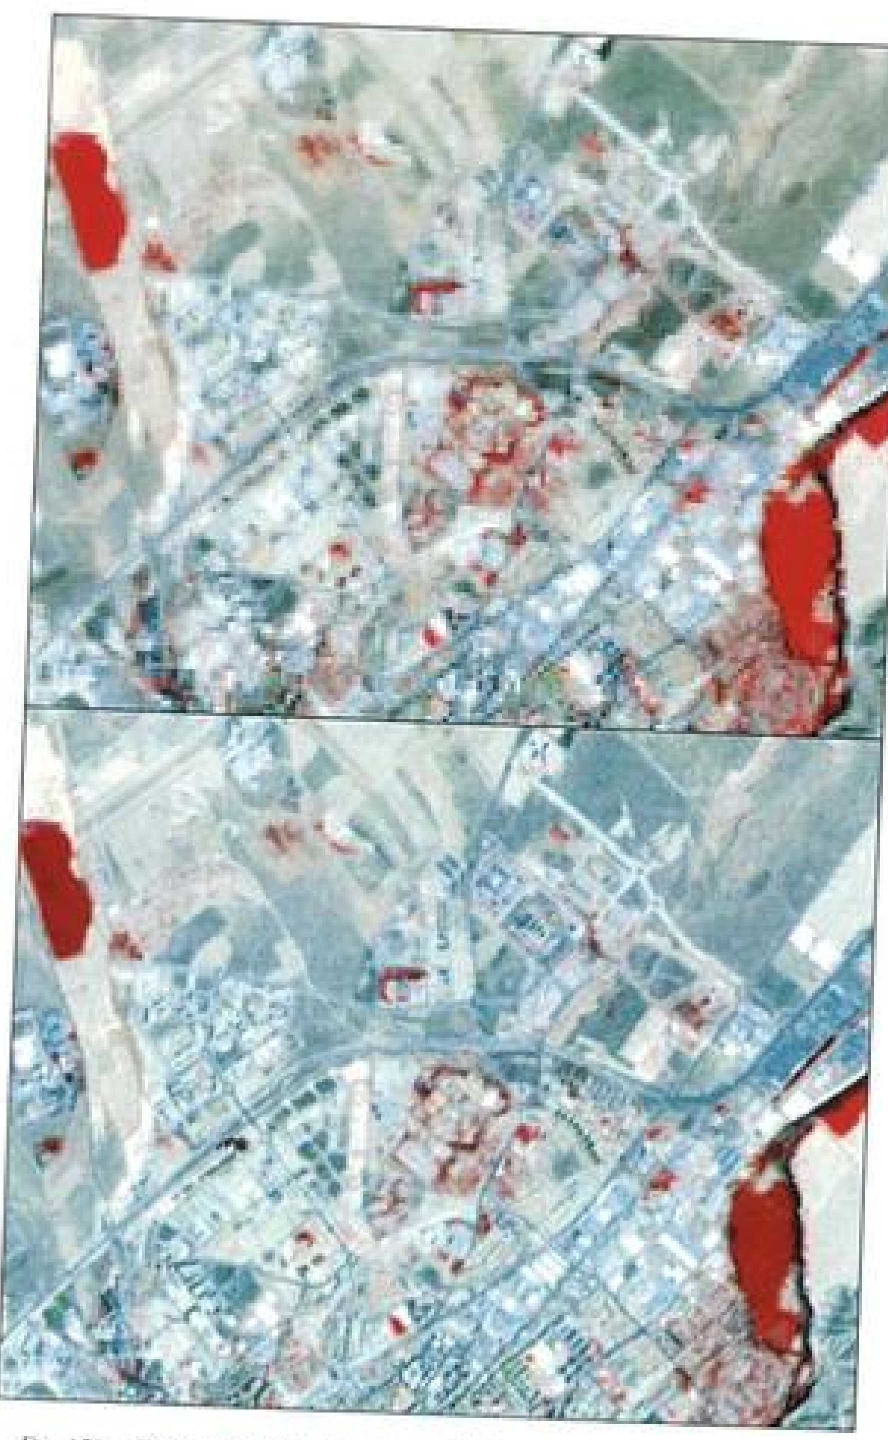


Fig. 15*. *Fusión del canal pancromático ETM y una composición en color 4/5/3 sobre la imagen Alcalá99: original (arriba), resultado de la fusión (abajo).*

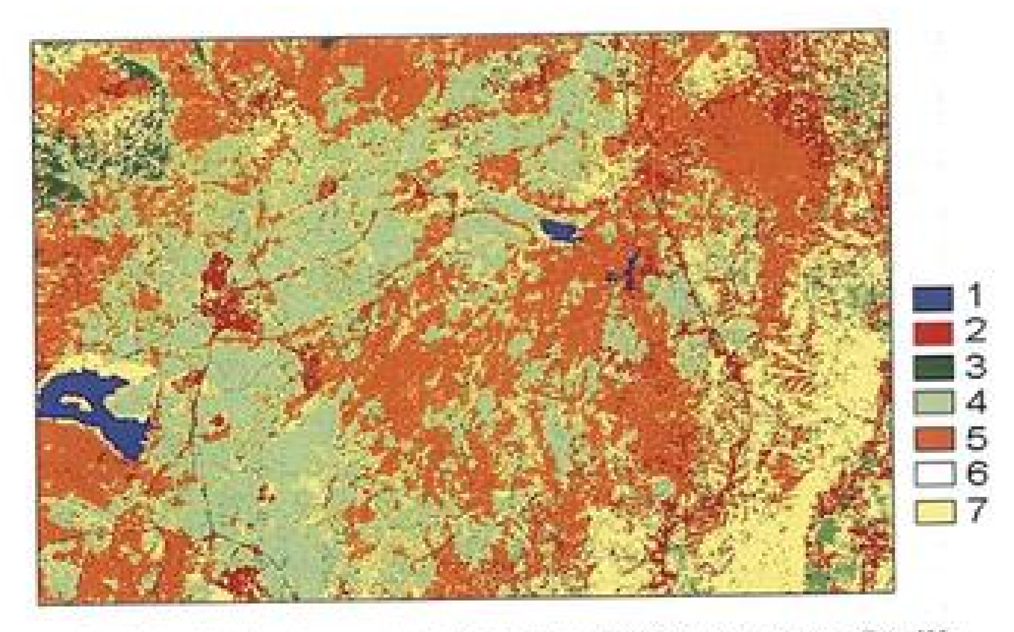


Fig. 16*. *Clasificación supervisada de máxima probabilidad sobre la imagen Torrel00: (1) Agua; (2) Urbano; (3) Pinar; (4) Pastizal; (5) Matorral-Encinar; (6) Suelo descubierto; (7) Cultivos.*

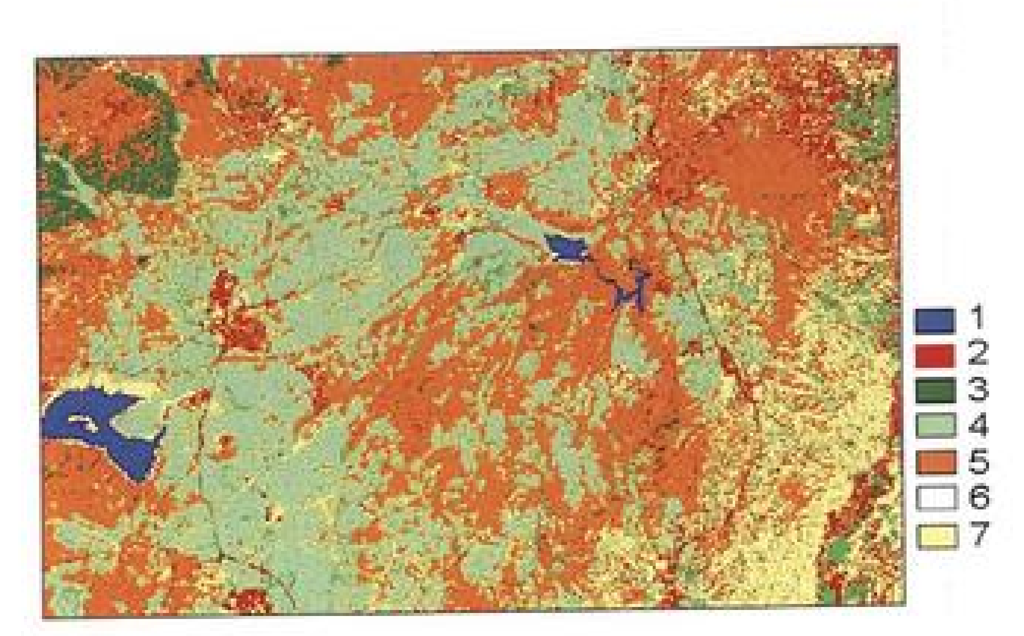


Fig. 17*. *Clasificación supervisada por redes neuronales sobre la imagen Torrel00 (la clave de color es igual a la figura anterior).*



FIG. 18*. *Imágenes multiestacionales del P.N.Cabañeros. A la derecha se incluye una foto de terreno tomada aproximadamente en las mismas fechas.*

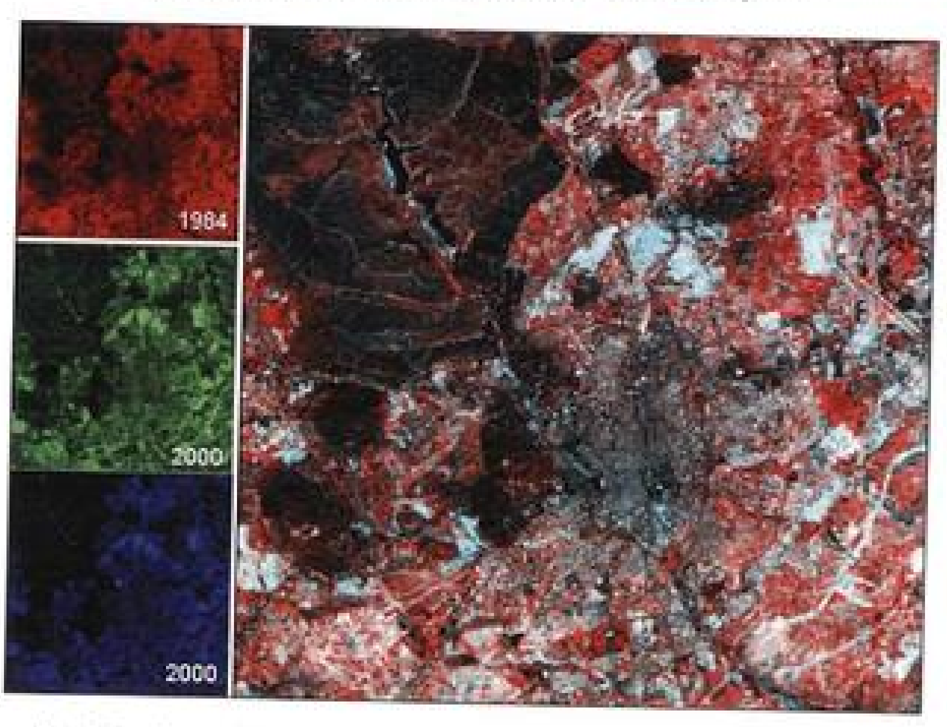


FIG. 19*. *Composiciones en color multitemporales sobre los alrededores de Madrid (en rojo, 1984; en azul y verde, 2000).*

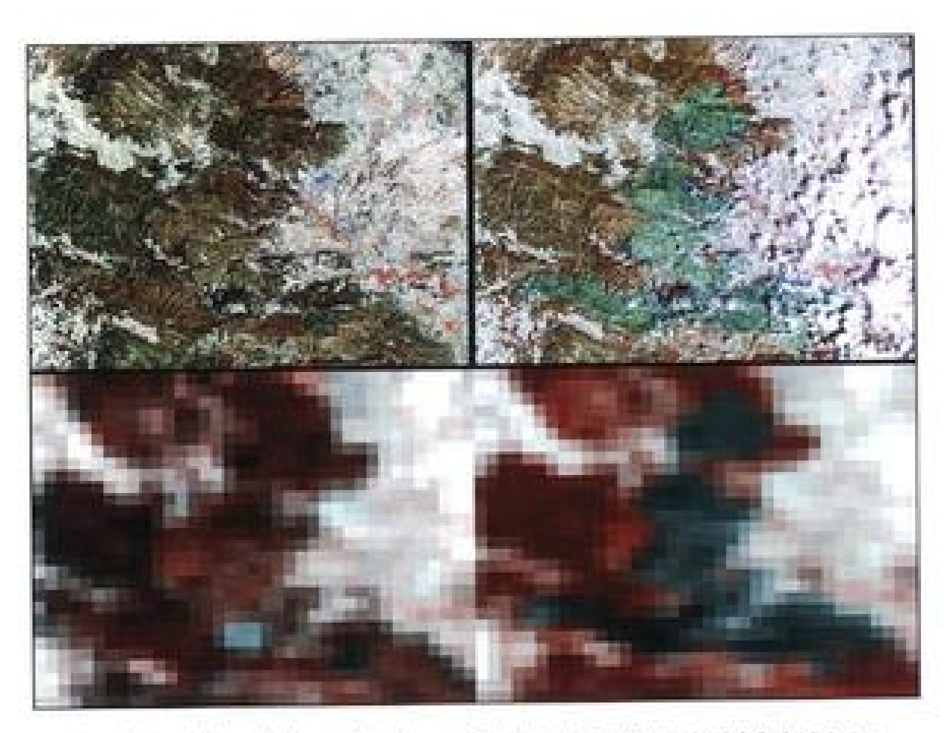


FIG. 20*. *Efecto de la resolución espacial sobre el patrón espacial de imágenes. Imágenes Landsat-TM (arriba) y NOAA-AVHRR (abajo), tomadas antes y después del incendio de Buñol (agosto de 1991).*



FIG. 21*. *Vista tridimensional del valle central del P.N. Cabañeros.*

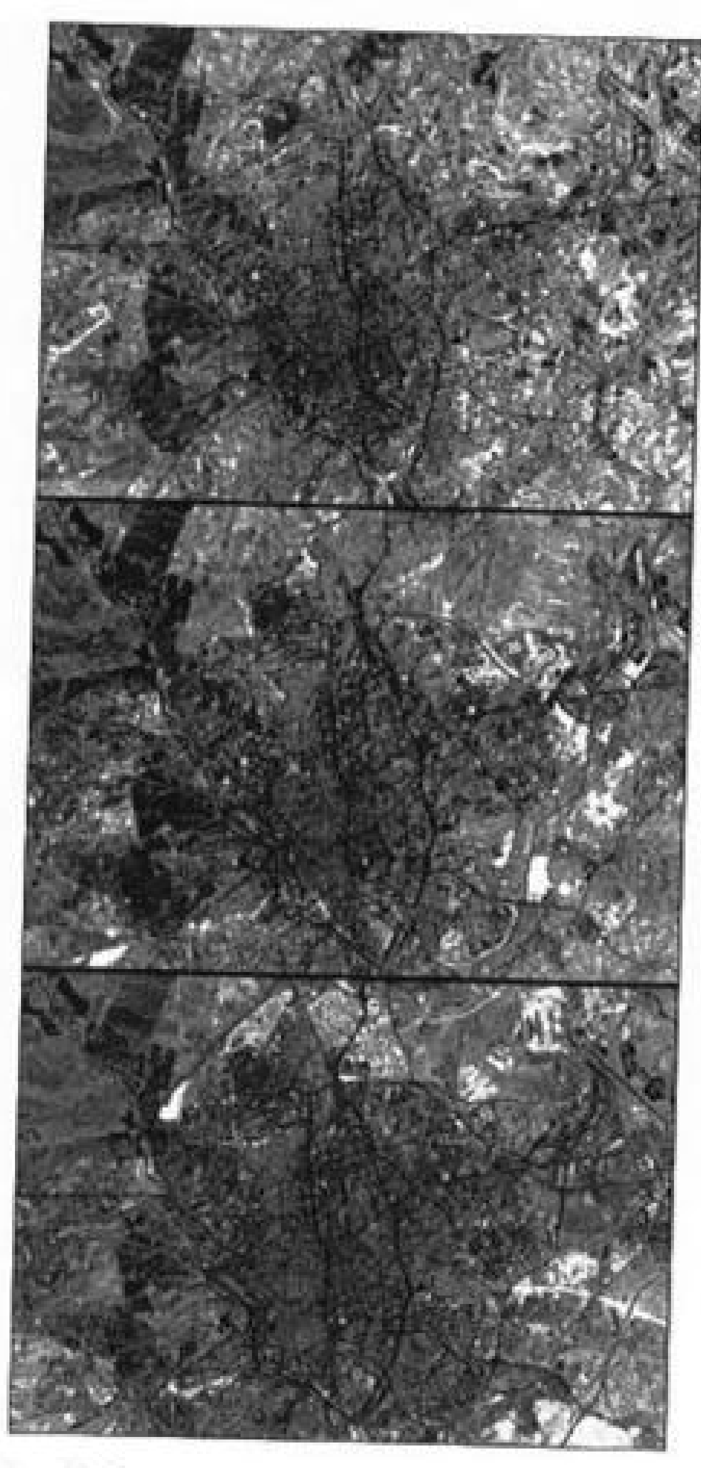


FIG. 22*. *Imágenes Landsat-TM de la ciudad de Madrid. De arriba a abajo: 1984, 1992, 2002.*

donde $NDVI_{max}$ y $NDVI_{min}$ corresponden a los valores del índice de vegetación observados como máxima y mínima cubierta vegetal, respectivamente, y k es un factor de normalización:

$$k = (\rho_{2v} - \rho_{1v}) / (\rho_{2s} - \rho_{1s}) \quad [6.54]$$

siendo ρ_{2v} y ρ_{1v} las reflectividades de la vegetación en las bandas 2 y 1 del AVHRR, respectivamente, mientras ρ_{2s} y ρ_{1s} indican las reflectividades del suelo en esos mismos canales.

A partir de la proporción de cobertura verde puede calcularse la emisividad de cada píxel multiplicando esa proporción por la emisividad media de la vegetación (ε_v = 0,952 para herbáceos secos, 0,983 para árboles y 0,985 para herbáceos verdes y arbustos. También puede aplicarse un valor promedio global de 0,985), y el resto por la emisividad media del suelo descubierto (ε_s = 0,968 para suelos arenosos; 0,972 para limosos y 0,974 para arcillosos. Aquí el valor promedio sería 0,96). De esta forma, tendríamos (Caselles y Sobrino, 1989):

$$\varepsilon = \varepsilon_v P_v + (1 - P_v)\varepsilon_s + d\varepsilon \quad [6.55]$$

y

$$\Delta\varepsilon = \Delta\varepsilon_v P_v + (1 - P_v)\Delta\varepsilon_s + d\Delta\varepsilon \quad [6.56]$$

donde los términos $d\varepsilon$ y $d\Delta\varepsilon$ evalúan, respectivamente, los efectos de cavidad de ε y $\Delta\varepsilon$, y pueden determinarse a partir de las características geométricas de las plantas, aunque tienen una contribución muy pequeña (los valores oscilan entre 0,004 y 0,0025 para las cubiertas vegetales más habituales: Caselles *et al.*, 1995). Otros métodos para estimar la emisividad se basan en las medidas de campo o laboratorio, en relaciones empíricas, técnicas de inversión y medidas especiales (Sobrino, 2000, cap. 11).

En la figura 6.42 aparece un ejemplo de obtención de la temperatura de superficie para el conjunto de la península Ibérica (imagen Ibérica01) utilizando el método propuesto previamente sobre una imagen AVHRR. Hemos incluido la temperatura de brillo original de la banda 4, la imagen de emisividad y la temperatura del suelo, ya corregida de atmósfera y emisividad. Además, se señala un perfil, en el sentido norte-sur, que atraviesa la mitad norte de la Península, desde el Cantábrico hasta el Valle del Tajo. Se observa el efecto de la corrección atmosférica y de emisividad sobre la temperatura final, con amplitudes que superan los 7 °C en algunos sectores. Por otro lado, la tendencia al aumento de la temperatura, de norte a sur, es bastante evidente, así como los accidentes montañosos que atraviesa el perfil, como la Cordillera Cantábrica y el Sistema Central, claramente diferenciados por el brusco decremento de la temperatura frente a los valles pre-cordilleranos (12-15 °C en la Cantábrica y unos 18-20 °C en el Sistema Central).

La observación térmica tiene gran interés para el seguimiento de fenómenos que afectan a la vegetación, como ya vimos en el capítulo 2. La temperatura de superficie está inversamente relacionada con el vigor vegetal, ya que la evapotranspiración libera calor y, en consecuencia, reduce la temperatura de la masa vegetal frente al suelo des-

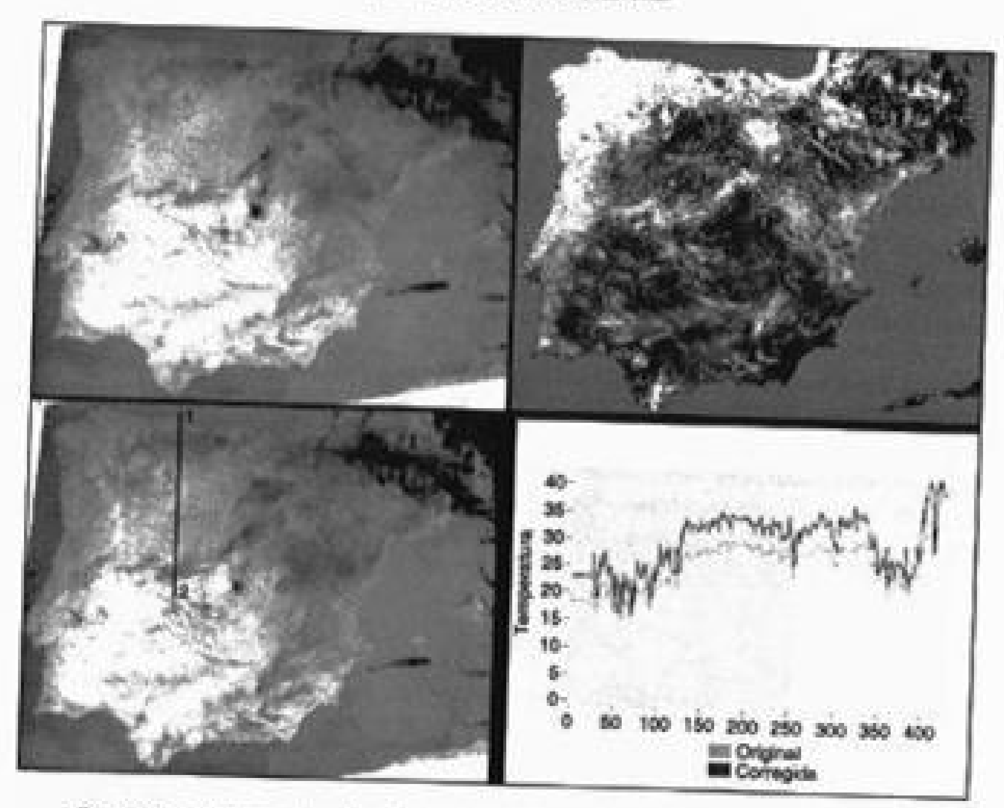


FIG. 6.42. *En la parte izquierda, temperatura de brillo (arriba) y corregida (abajo) de la imagen Ibérica01. En la derecha, emisividad (arriba), y perfil de temperaturas tomado desde el Cantábrico, hasta la Meseta sur.*

cubierto. Por tanto, la evolución temporal de la temperatura de superficie nos permite estimar las condiciones de vigor o estrés de la planta, de cara a estudios de rendimiento agrícola (Caselles y Sobrino, 1989) o de riesgo de incendios (Vidal *et al.*, 1994), además de su clara aplicación a estudios oceanográficos o pesqueros (Barreto, 2000).

6.2.5. *Detección de nubes*

La cubierta nubosa supone el principal obstáculo para el análisis de la variación a corto plazo de una determinada superficie terrestre cuando estemos trabajando con sensores ópticos o térmicos. Puesto que la presencia de nubes introduce una severa distorsión en las series temporales de imágenes, en muchas ocasiones resulta imprescindible aplicar alguna técnica que permita discriminarlas, ya sea para aislar ese sector de otros análisis (cuando el interés se centra en la cubierta que está debajo de la nube), ya para retener estos valores (cuando precisamente el interés es la propia nube).

El problema de discriminación de nubes es una tarea muy frecuente en teledetección que ha recibido la atención de numerosos autores. Aquí lo trataremos únicamente con un enfoque práctico, de cara a proponer algunas soluciones para aislar los píxeles nubosos de posteriores tratamientos.

Una de las formas más eficaces de discriminar las nubes se apoya en la interpretación visual (Cracknell, 1997), ya que el intérprete puede incluir una serie de criterios espectrales y espaciales que son complicados de definir en términos digitales. Ahora bien, este método también presenta una serie de inconvenientes (Simpson y Gobat, 1996): se trata de una labor tediosa, ya que hay que visualizar las imágenes para detectar las nubes; no es estadísticamente reproducible para otros lugares geográficos ni otros investigadores, y requiere de conocimiento y experiencia en fotointerpretación.

Por estas razones, habitualmente los criterios de detección de nubes se basan en la aplicación de distintas técnicas de análisis digital. Entre ellas, son más numerosas las basadas en la aplicación de una serie de tests consecutivos, que permiten discriminar un píxel como nuboso cuando cumple una serie de condiciones, ya sean espectrales (lo más habitual), espaciales o una mezcla de las dos (Bastarrika, 2000). Otros criterios propuestos se basan en técnicas de clasificación no supervisada (por ejemplo, el método ASMC, de agrupamiento y separación iterativa, ideado por Simpson y Gobat, 1996, o en índices espectrales, como el *tasseled cap*, que luego veremos: Labuto, 1991).

El principal problema de los algoritmos de umbrales múltiples es establecer unos valores críticos que sean de validez universal. Dada la gran variedad de tipos de nubes, espesores y áreas donde se sitúan, resulta complejo establecer unos límites bien adaptados a cualquier situación. Posiblemente el intérprete tendrá, en algunas ocasiones, que adaptar los umbrales propuestos hacia valores más o menos conservadores, según se pretenda reducir al máximo los errores de omisión (nubes que no se detecten) o de comisión (áreas no nubladas que se etiqueten como tales). Si el objetivo es eliminar con toda seguridad las nubes, los límites pueden ser bastante amplios, mientras si se pretende reducir los errores de comisión será necesario restringir más rigurosamente esos umbrales.

Uno de los algoritmos de umbrales múltiples más utilizados en la detección de nubes es el propuesto por Saunders y Kriebel (1988). Se basa en 5 pruebas para imágenes diurnas y otras 5 para imágenes nocturnas que se aplican píxel a píxel, determinando si está despejado, parcial o totalmente nublado. Por ejemplo, para las imágenes diurnas estos cinco tests son (fig. 6.43: Bastarrika, 2000):

1. Prueba del umbral térmico: se aplica para la determinación de nubes gruesas a partir de un umbral de temperatura de brillo en 12 μm (banda 5 del AVHRR). La temperatura de brillo de esa banda es más adecuada para detectar nubes que la ofrecida por la banda 4 (11 μm) porque las nubes tienen una mayor profundidad óptica en esas longitudes de onda. Si la temperatura es menor que un umbral absoluto, el píxel se identifica como nuboso. Este método, lógicamente, usa diferentes umbrales para tierra y mar. Para determinar el umbral se identifican en la imagen las zonas más frías libres de nubes tanto en tierra como en mar. A la temperatura de esas zonas más frías se les resta una cantidad (normalmente mayor que 2 °C) y así puede obtenerse el umbral deseado, uno para mar y otro para tierra. El hecho de seleccionar un único umbral puede ser correcto para terrenos llanos u ondulados, pero hay que tener mucho cuidado al establecer umbrales en una imagen muy extensa, donde exista terreno montañoso: el decremento de la temperatura con la altitud puede provocar la clasificación de píxeles fríos, pero libres de nubes, como nubosos. Este problema puede solventarse utilizando

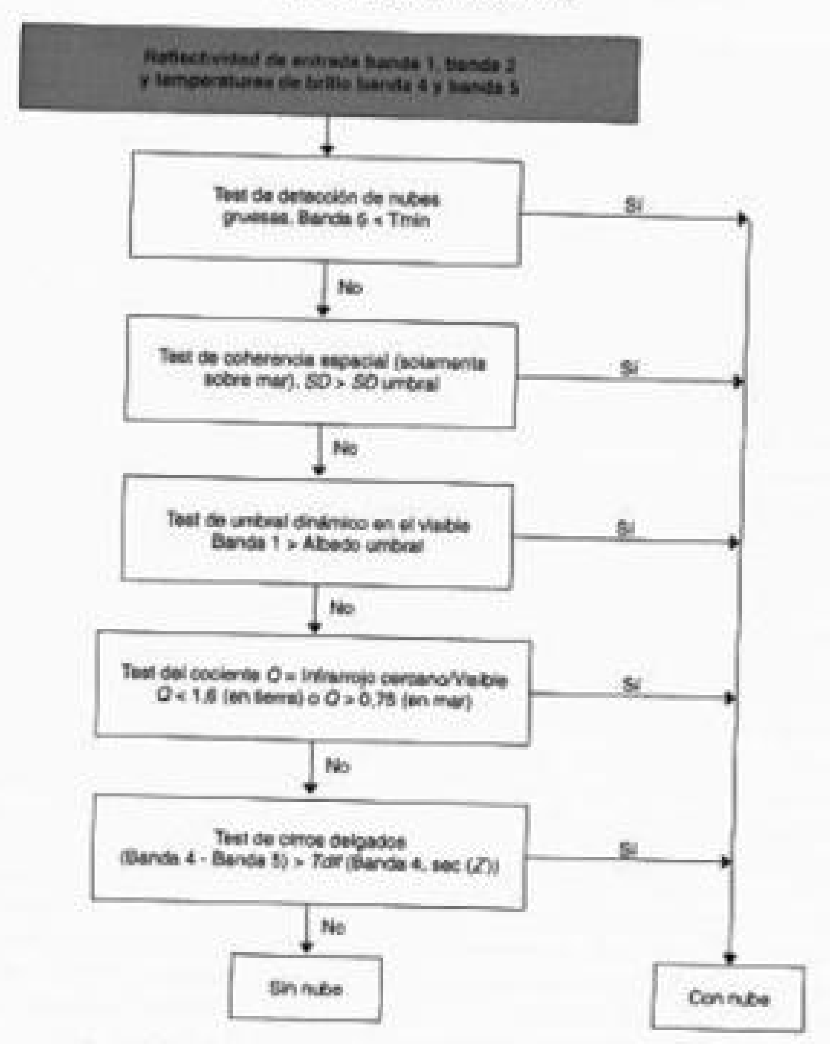


FIG. 6.43. *Esquema del algoritmo de discriminación de nubes.* (Adaptado de Saunders y Kriebel, 1988.)

umbrales dinámicos, por ejemplo basados en compuestos multitemporales de temperaturas.

2. Prueba de coherencia y uniformidad espacial. Intenta comparar la temperatura de brillo de un píxel en la banda 4 con la de su entorno, basándose en la desviación estándar (SD) de una ventana de 3 × 3 píxeles. La idea de este criterio es que la variabilidad de la temperatura de brillo sobre píxeles contaminados por nubes debería ser mayor que para píxeles libres de nubes. Los umbrales de la desviación estándar son empíricamente determinados y se mantienen constantes para todo el área.

3. Prueba del umbral de reflectividad dinámica. Casi todas las nubes tienen alta reflectividad en el visible e IRC, mucho mayor que la correspondiente a la superficie terrestre y marina. En zonas terrestres, la reflectividad en la banda 1 tiende a ser menor

que en la 2; por tanto, el contraste tierra-nube será mucho más acentuado en la banda 1. Sin embargo, en el mar suele utilizarse la 2, debido a que está mucho menos afectada por los aerosoles y la dispersión *Rayleigh*.

4. Prueba del cociente entre las reflectividades de las bandas 2 y 1 (*Q*). Los valores de este cociente para píxeles nublados son cercanos a 1 debido a que los efectos de dispersión (dispersión Mie) son parecidos para ambas bandas. Sobre tierra (zonas con vegetación) los valores de *Q* son superiores a la unidad debido a la mayor reflectividad en el IRC que en el VIS. Sobre el mar, en cambio, ocurre lo contrario. Así, se determinan dos umbrales: sobre tierra, si $Q < 1{,}6$ se supone que el píxel es nuboso, mientras que sobre mar, si $Q > 0{,}75$ el píxel también se supone nuboso. Este método no trabaja bien en áreas con reflejos solares, donde el valor *Q* es cercano a 1 y, por tanto, es similar a los valores obtenidos para las nubes.

5. Prueba de la diferencia de temperaturas de brillo (banda 4-banda 5). Finalmente, el quinto criterio propuesto por Saunders y Kriebel utiliza la diferencia de temperatura de brillo entre las bandas 4 y 5. La variación de las emisividades de las nubes con la longitud de onda hace que haya diferencias de temperatura entre ambas bandas. Estas diferencias de temperatura pueden usarse, por ejemplo, para detectar cirros bastante delgados porque las nubes tienen diferentes emisividades a diferentes longitudes de onda. Sobre nubes, las diferencias de temperatura de brillo pueden ser de hasta 6 K. Las diferencias sobre píxeles libres de nubes, sin embargo, suelen ser menores (a menudo menor que 1 K), aunque dependerá de la cantidad total de vapor de agua en la atmósfera y del ángulo cenital. Saunders y Kriebel proponen una serie de umbrales para estas diferencias, basados en el ángulo cenital solar.

La figura 6.44 presenta un ejemplo de la aplicación de estas pruebas sucesivas sobre una imagen AVHRR de invierno que incluye toda la península Ibérica, con cierta cobertura nubosa. Resulta evidente la buena discriminación de las nubes que facilita el algoritmo de Saunders y Kriebel, si bien en este caso se ha modificado un poco los criterios para establecer los umbrales. Aquí, en lugar de valores absolutos, se han primado las diferencias de contexto espacial frente a imágenes sintéticas de temperatura má-

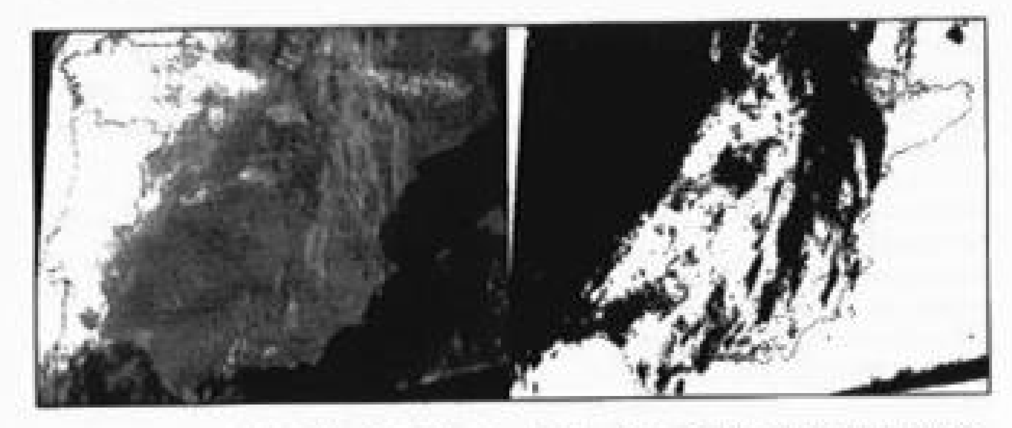


FIG. 6.44. *Ejemplo de aplicación del algoritmo de Saunders y Kriebel a una imagen AVHRR de la península ibérica tomada el 12 de enero de 1999.* (Cortesía: Aitor Bastarrika.)

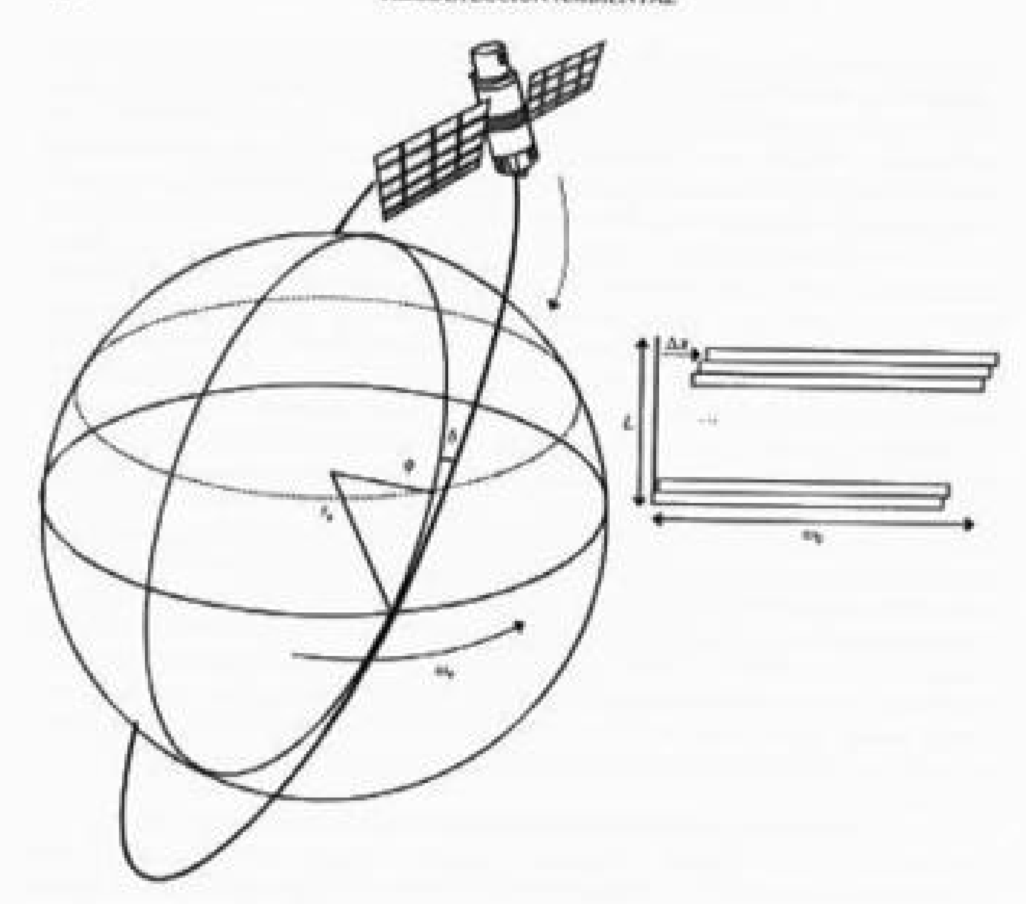


FIG. 6.45. Errores geométricos causados por la rotación terrestre. (Adaptado de Richards, 1993.)

1. Inclinación de la imagen. Tanto el NOAA como otros satélites de órbita polar adquieren las imágenes con un pequeño ángulo respecto al norte geográfico. Esto implica una inclinación del eje de la imagen hacia el noreste. Además, durante el tiempo de adquisición de la imagen, la Tierra se desplaza hacia el este, en una distancia variable con la latitud, la velocidad angular del satélite y el tamaño del área cubierta en la imagen. Estos problemas pueden obviarse de acuerdo a las siguientes fórmulas (Richards, 1993, pp. 48-54; fig. 6.45).

$$\Delta x = \Delta x_e \cos \delta \quad [6.57]$$

$$\Delta x_e = v_e T_s \quad [6.58]$$

$$v_e = \omega_e r_e \cos \phi \quad [6.59]$$

$$T_s = L / (r_e \omega_0) \quad [6.60]$$

De la primera se deduce que el desplazamiento de la imagen en el eje x (Δx) es igual al desplazamiento debido al movimiento de la tierra (Δx_e) multiplicado por el coseno del ángulo de inclinación de la órbita (δ). A su vez, de [6.58] calculamos ese desplazamiento de la Tierra (Δx_e) a partir de su velocidad angular (v_e) y del tiempo de adquisición de la imagen (T_s). La velocidad angular puede calcularse a partir de la velocidad rotacional de la Tierra (ω_e = 72,72 microradianes/s), del radio terrestre (r_e = 6.378 km) y de la latitud de la imagen (ϕ). Por su parte, el tiempo de adquisición está en función del área cubierta (L) y de la velocidad angular del satélite (ω_0). En definitiva, basta saber la inclinación de la órbita del satélite, su velocidad angular y el área que abarcan sus imágenes para posicionarlas aproximadamente hacia el norte.

2. Distorsión panorámica. En cualquier sensor óptico las imágenes se adquieren desde un punto de observación, por lo que los parámetros de adquisición (sobre todo la distancia sensor-Tierra) sólo son exactos en la vertical del mismo (nadir). Entre otros efectos de esta observación panorámica, uno de los más agudos es la variación del tamaño del píxel desde el nadir a los extremos, pues aumenta la distancia entre el sensor y el punto observado. En el caso de imágenes de pequeño campo de visión (como el Landsat-TM, SPOT-HRV o IRS-1C) ese efecto es poco importante, pues adquieren imágenes casi verticales. No es así para las imágenes de los sensores globales, que cuentan con un gran ángulo de barrido, lo que implica errores considerables hacia los extremos del área observada (fig. 6.46).

FIG. 6.46. Efecto de la observación panorámica sobre la geometría de la imagen. (Adaptado de Richards, 1993.)

Una sencilla corrección de este efecto panorámico viene dada por las fórmulas siguientes:

$$p' = p / \cos\gamma \qquad [6.61]$$

en la dirección y del píxel (latitud), y

$$p'' = p / \cos^2\gamma \qquad [6.62]$$

en la dirección x del píxel (longitud), siendo p el tamaño del píxel en el nadir y γ el ángulo de barrido (formado por la línea de observación y la vertical al sensor: fig. 6.46). En este esquema se asume que el campo de visión instantáneo (IFOV) es constante. Esta corrección permite ajustar el tamaño del píxel con la distancia al nadir, a lo largo de cada línea de barrido.

3. Efecto de la curvatura terrestre. Mientras en el caso de la fotografía aérea, el área observada permite asumir la Tierra como plana, en aquellos sensores que observan una superficie muy vasta, como es el caso del AVHRR, la esfericidad terrestre no puede obviarse. Para mitigar este efecto puede abordarse la siguiente corrección (Richards, 1993: fig. 6.47):

$$p_c = \frac{\beta(h + r_t(1 - \cos\varphi))}{\cos\gamma\cos(\gamma + \varphi)} \qquad [6.63]$$

donde p_c indica el tamaño del píxel corregido del efecto de curvatura, β es el ángulo de visión instantánea, h la altura del sensor, r_t el radio de la Tierra, γ el ángulo de barrido y φ el formado por el centro del píxel observado y el centro de la Tierra.

A partir de estas ecuaciones, conociendo la posición geográfica del satélite, puede navegarse la imagen, generando una malla de coordenadas x, y con los ND adquiridos por el sensor más aproximados a cada posición. Este proceso de interpolación es relativamente similar al que veremos para la corrección con puntos de control. El conjunto del proceso implica un volumen considerable de cálculo, ya que las ecuaciones de ajuste son bastante complejas. En ocasiones, los modelos orbitales se apoyan en la localización de algún punto de control terrestre, para mejorar la estimación de las condiciones de orientación del satélite *(attitude)*.

La figura 6.48 incluye una secuencia de imágenes AVHRR adquiridas en tres días consecutivos. A la izquierda aparecen las imágenes originales, mostrando los efectos de distorsión geométrica que estas imágenes incluyen. Los extremos aparecen severamente deformados, cambiando esa área según se desplaza el centro de la imagen hacia el oeste. A la derecha aparece un sector próximo a la ciudad de Valencia, tras la corrección orbital, referenciada en proyección UTM. Como puede observarse, pese a la gran diferencia en la geometría de las imágenes originales, la corrección consigue posicionar las imágenes de forma bastante similar entre ellas.

Esta solución será suficiente para aplicaciones globales, en donde se pretendan analizar grandes extensiones. Sin embargo, para análisis multitemporales más detallados no facilita habitualmente la precisión requerida. Como veremos en el capítulo de detección de cambios, un proceso previo imprescindible para determinar qué se ha modificado entre dos o más imágenes es que se refieran exactamente a la misma zona. Pequeños desplazamientos entre los píxeles de las imágenes que se comparan estarían mostrando cambios ficticios. La importancia de este factor puede llegar a ser muy considerable (Roy, 2000; Townshend *et al.*, 1992), por lo que resultará imprescindible mejorar esa corrección con otros ajustes más detallados cuando se pretendan analizar superficies que ocupen pocos píxeles (Martín, 1998). El efecto es especialmente evidente en zonas costeras (fig. 6.49).



FIG. 6.47. *Errores provocados por la curvatura terrestre.* (Adaptado de Richards, 1993.)

6.3.3. *Corrección a partir de puntos de control*

La segunda alternativa de corrección es más inductiva. Asume que no se conoce el origen de los errores, pero que éstos pueden modelarse a partir de ajustar unas

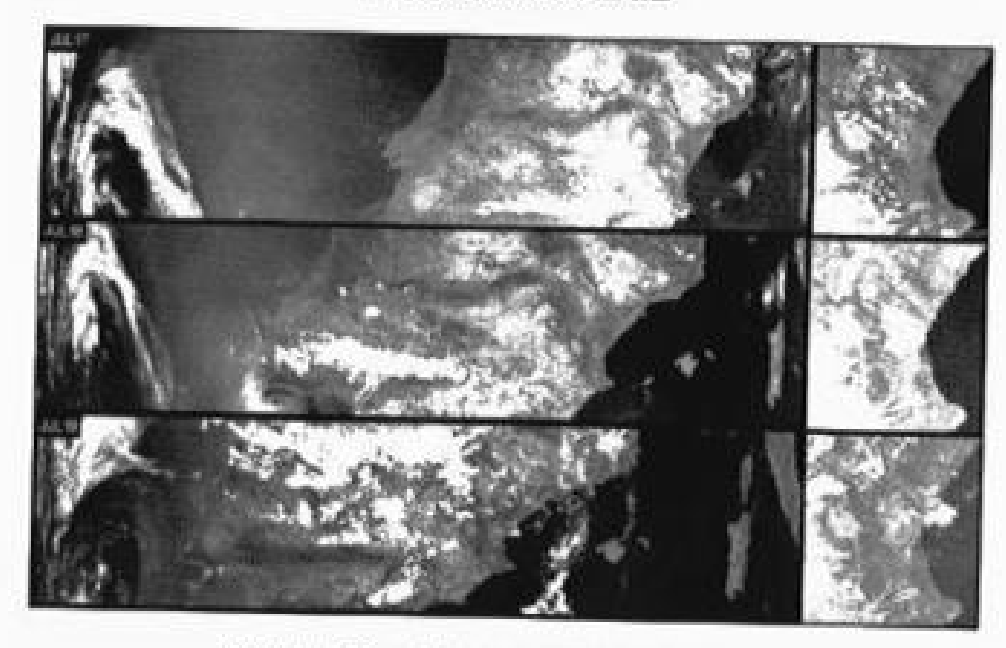


FIG. 6.48. *Efecto de la corrección orbital de imágenes.* (Imágenes adquiridas por el AVHRR en julio de 1991.)

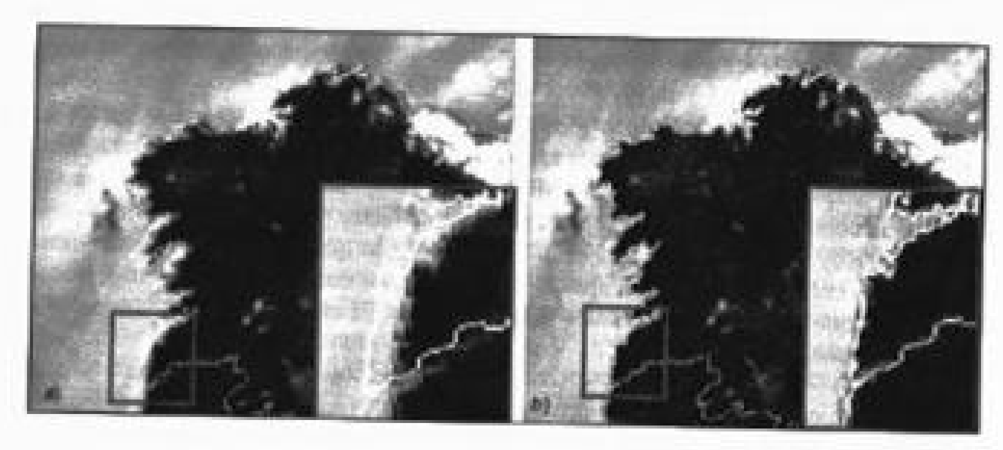


FIG. 6.49. *Mejora en los ajustes orbitales mediante correcciones con puntos de control: a) ajuste orbital; b) añadiendo puntos de control.* (Cortesía: M. Pilar Martín.)

ecuaciones empíricas a un conjunto de puntos, de los que se conoce tanto las coordenadas de la imagen a corregir como las del mapa o imagen de referencia. En ambos casos, la corrección se realiza en tres fases (fig. 6.50): 1) localización de puntos comunes a la imagen y al mapa (o a otra imagen de referencia), 2) cálculo de las funciones de transformación entre las coordenadas de la imagen objetivo y las de referencia, y 3) trasferencia de los ND originales a la nueva posición, definida por la transformación previa.

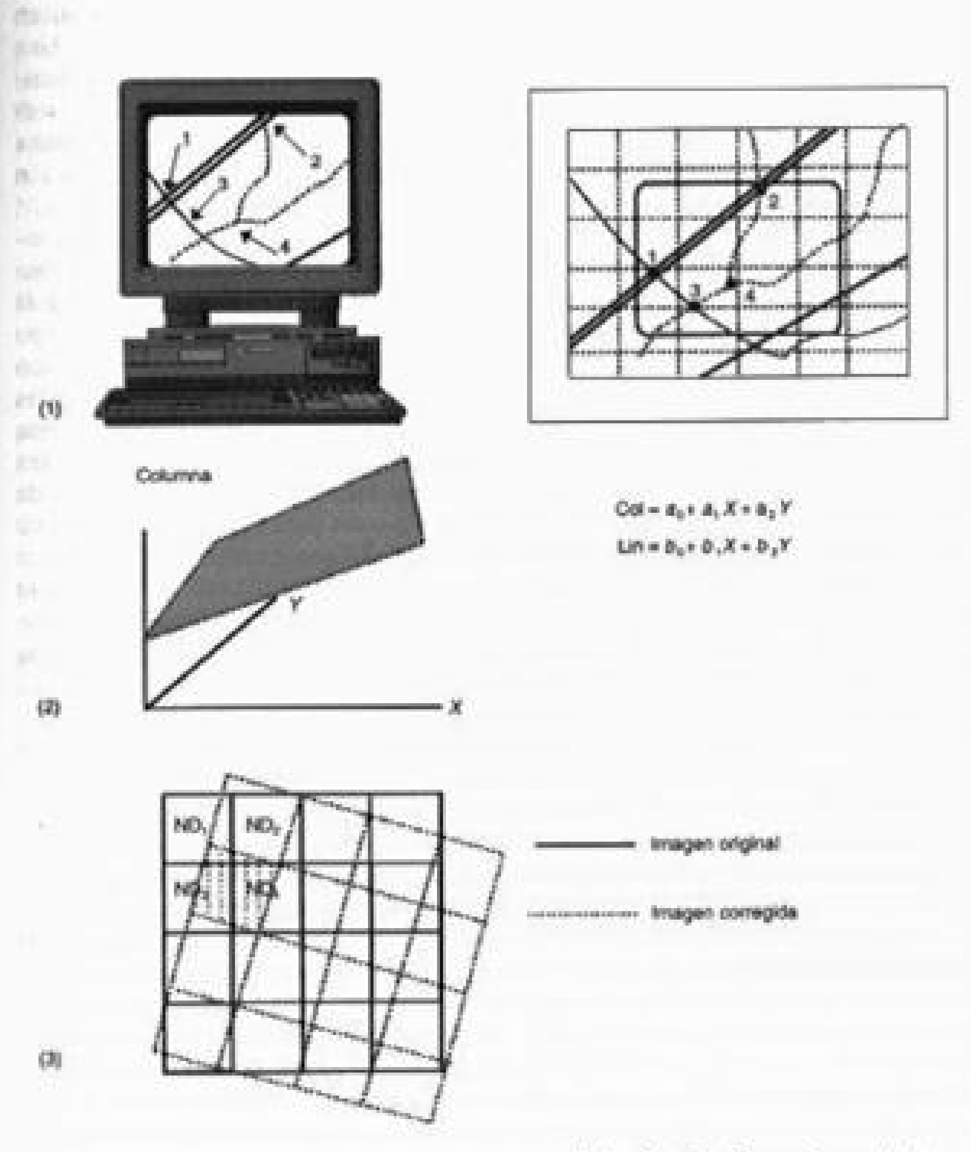


FIG. 6.50. *Fases de la corrección con puntos de control: 1) selección; 2) ecuaciones de ajuste; 3) generación de la imagen corregida.*

6.3.3.1. Establecimiento de puntos de control

Para calcular cualquier función entre dos o más variables es necesario contar previamente con una serie de observaciones comunes a todas ellas. De la misma forma, las funciones que permiten transformar coordenadas entre la imagen y el mapa precisan localizar una serie de puntos comunes a ambos, que se conocen como puntos de control. A partir de las coordenadas imagen y mapa de esos puntos se calculan las funciones de ajuste, de forma similar a como se obtienen en otras regresiones multivariables. En consecuencia, la calidad del ajuste dependerá del rigor con que se localicen esos puntos, y de cómo definan realmente los errores geométricos de la imagen. Una inexacta localización de esos puntos, tanto en la imagen como en el mapa, o una distribución muy sectorizada, implicará una estimación inadecuada y, por tanto, una corrección geométrica errónea. En definitiva, el establecimiento de puntos de control resulta la fase más crucial del proceso de corrección y la que demanda mayor dedicación humana.

Para que el ajuste entre imagen y mapa sea correcto se requiere atender a tres aspectos en la selección de los puntos de control: número, localización, y distribución.

El número idóneo de puntos de control depende de la complejidad geométrica de la imagen. Si se trata de zonas planas, adquiridas por un sensor de estrecho campo de visión, la transformación imagen-mapa puede basarse en ecuaciones lineales simples. Por el contrario, si se trata de un terreno rugoso o el sensor varía notablemente las condiciones de observación será preciso aplicar funciones de transformación más complejas, con polinomios de segundo o tercer grado. Lógicamente, cuanto mayor sea el grado de la ecuación de ajuste se precisará también un mayor número de puntos de control. Matemáticamente sólo son necesarios 3 puntos para una función de ajuste de 1.er grado, 6 para una de 2.º grado y 10 para una de 3.er grado. Ahora bien, conviene superar con creces ese listón mínimo para garantizar una buena conformidad entre imagen y mapa. Bernstein (1978) aconsejaba seleccionar entre 14 y 20 puntos para corregir una imagen MSS, mientras el *National Remote Sensing Center* inglés utilizaba de 100 a 120 puntos para hacer lo propio con una imagen TM (Davison, 1984). Para una zona pequeña (512 × 512 píxeles, por ejemplo), 10 o 12 puntos y una transformación de primer grado serán normalmente suficientes. En caso de que el contraste topográfico sea importante convendrá seleccionar un mayor número de puntos, y acudir a polinomios de transformación más complejos.

En cuanto a la localización, se recomienda que sean puntos claramente identificables en la imagen y en el mapa, preferiblemente rasgos humanos del paisaje no sujetos a dinamismo temporal: cruces de carreteras, caminos, vías de ferrocarril, etc. Siempre que sea posible, no conviene señalar puntos en la línea de costa, pues el efecto de la marea puede modificar la localización exacta de un accidente geográfico. La misma idea puede aplicarse a los cursos de agua o embalses, que sufren alteraciones estacionales, en ocasiones de gran importancia. Algún elemento destacado de la vegetación podría utilizarse como punto de control, siempre que se disponga de la cartografía temática apropiada y no se hayan producido cambios entre la fecha de la imagen y la del mapa. En caso de que se pretenda el registro de dos imágenes, la búsqueda de puntos comunes resulta más sencilla, ya que hay rasgos visualizables en una imagen que no se recogen en la cartografía básica, como es el caso de manchas características de vegetación o ciertas parcelas agrícolas. La mayor parte de los programas de interpretación digital permiten visualizar las dos imágenes a corregir simultáneamente, lo que facilita mucho la selección de los puntos de control.

Respecto a su distribución, conviene que estos puntos se sitúen uniformemente sobre todo el territorio abarcado en la imagen. Esto evitará errores debidos a una ponderación excesiva de algún sector del área de estudio, en donde el ajuste será bueno a expensas de otros sectores de la imagen. Esto es especialmente importante cuando la zona presente contrastes topográficos y se utilicen ecuaciones de segundo o tercer grado. Aunque el efecto de desplazamiento del relieve es menor que en el caso de la fotografía aérea (debido a la altura de la órbita), también en las imágenes de satélite existe un efecto de desplazamiento que puede causar serios problemas en su ajuste cartográfico. Para intentar paliarlos, cuando no se disponga de un buen modelo digital de elevaciones puede ser recomendable tomar puntos de control sobre áreas de distinta altitud, siempre que éstas resulten bien identificables en la imagen (Itten y Meyer, 1993; Novak, 1992).

Nuestra propia experiencia indica que la selección de puntos de control es una tarea bastante laboriosa. En caso de un registro entre dos imágenes, el proceso se simplifica, puesto que es más sencillo identificar puntos comunes entre dos imágenes que entre imagen y mapa. En el primer caso pueden utilizarse cruces de caminos y rasgos destacados de la vegetación, de difícil o imposible localización en un mapa. Además, en el caso de corregir distintas imágenes de la misma zona para un análisis multitemporal puede automatizarse el proceso de búsqueda de puntos comunes, a partir de señalar en una sola, de modo muy preciso, esos puntos, situando en las otras unas ventanas de búsqueda, en torno a cada punto de control (Díez de Arribas y Nicolás, 2001; Ortí *et al.*, 1979).

La figura 6.51 recoge la localización de los puntos de control seleccionados para la imagen Madrid92. Se trata ésta de una zona especialmente idónea para esta labor, por cuanto existen múltiples rasgos humanos, claramente identificables sobre la imagen y el mapa. Para simplificar el comentario hemos señalado once puntos de control. La tabla 6.6 incluye las coordenadas columna y línea de la imagen, y X e Y del mapa para esos puntos. La cartografía base se corresponde a una hoja 1:25.000 del Instituto Geográfico Nacional, realizada en proyección U.T.M.

6.3.3.2. Cálculo de las funciones de transformación

Como se comentó más arriba, la corrección digital de la geometría de una imagen se realiza estableciendo unas funciones, que pongan en relación las coordenadas de la imagen con las del mapa. De esta forma, a partir de las coordenadas X, Y del mapa puede estimarse que columna y línea de la imagen corresponde a esa localización. Esquemáticamente esta transformación puede expresarse como (Mather, 1998):

$$\hat{s} = \sum_{j=0,m} \sum_{k=0,m-j} a_{j,k} X^j Y^k \qquad [6.64]$$

donde $\hat{s}$ indica la coordenada estimada de la imagen corregida, que se obtiene a partir de las coordenadas del mapa X e Y. El subíndice m indica el grado del polinomio de ajuste. El caso más simple sería el de una ecuación lineal, en donde:

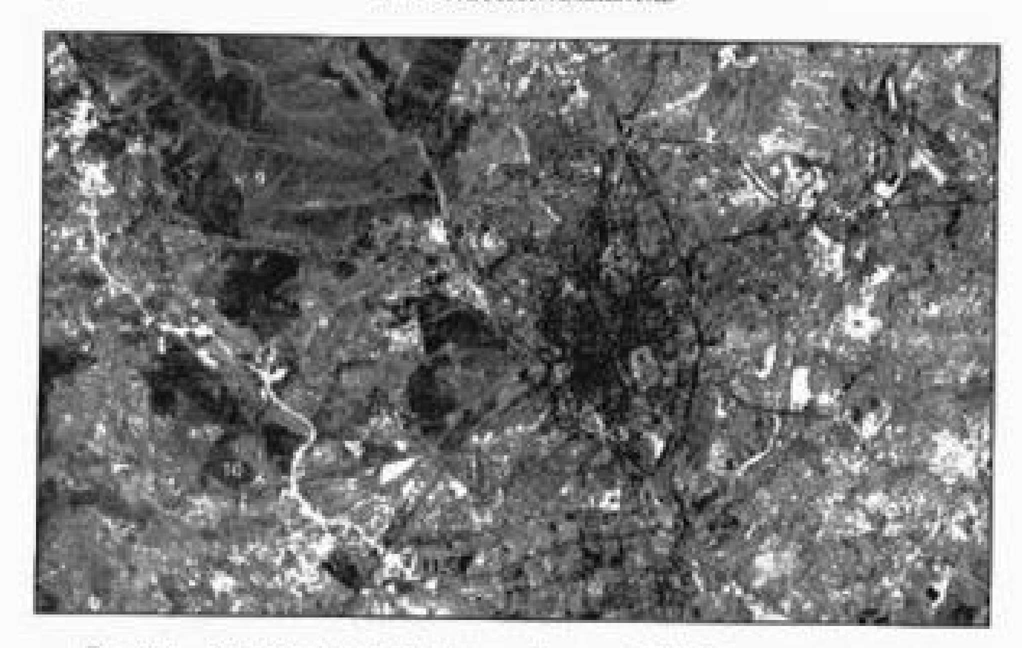


FIG. 6.51. *Puntos de control utilizados para la corrección de la imagen de Madrid92.*

$$\hat{c}_i = a_0 + a_1 X_i + a_2 Y_i$$
$$\hat{l}_i = b_0 + b_1 X_i + b_2 Y_i \qquad [6.65]$$

donde $\hat{c}$ y $\hat{l}$ son las coordenadas estimadas columna y línea, respectivamente, para unas coordenadas determinadas del mapa, X_i e Y_i.

Como puede comprobarse, se trata de una regresión lineal múltiple, donde a_0, a_1, a_2, b_0, b_1 y b_2 son los coeficientes de regresión; X_i e Y_i, las variables independientes, y c_i, l_i las dependientes. También podrían formularse otras dos ecuaciones similares, en donde las variables estimadas fueran las coordenadas X, Y del mapa, a partir de las coordenadas c, l de la imagen. En definitiva, la conversión puede realizarse en un doble sentido: desde las coordenadas del mapa a la imagen y viceversa.

Al igual que en la regresión convencional, estas funciones pueden definirse gráficamente por un plano, que expresa la relación entre las coordenadas de las variables independientes (eje X e Y), y la variable dependiente (eje c o l). Desde el punto de vista práctico, conviene considerar que basta una función lineal para abordar un amplio conjunto de transformaciones de la imagen, como cambiar su escala y origen, inclinarla, modificar la relación entre sus ejes y rotarla (fig. 6.52). Estas alteraciones serán suficientes para corregir imágenes pequeñas, siempre que no se presenten contrastes altimétricos importantes. En caso de precisar una modificación más rigurosa puede acudirse a funciones de segundo o tercer grado, en donde se abordan alteraciones geométricas no lineales (en otras palabras, la función no se define por un plano, con ejes lineales, sino por una superficie, con ejes curvilíneos). Por razones de mayor sencillez en la exposición nos centraremos en las funciones de primer grado, si bien pueden aplicarse los comentarios al caso de polinomios más complejos.

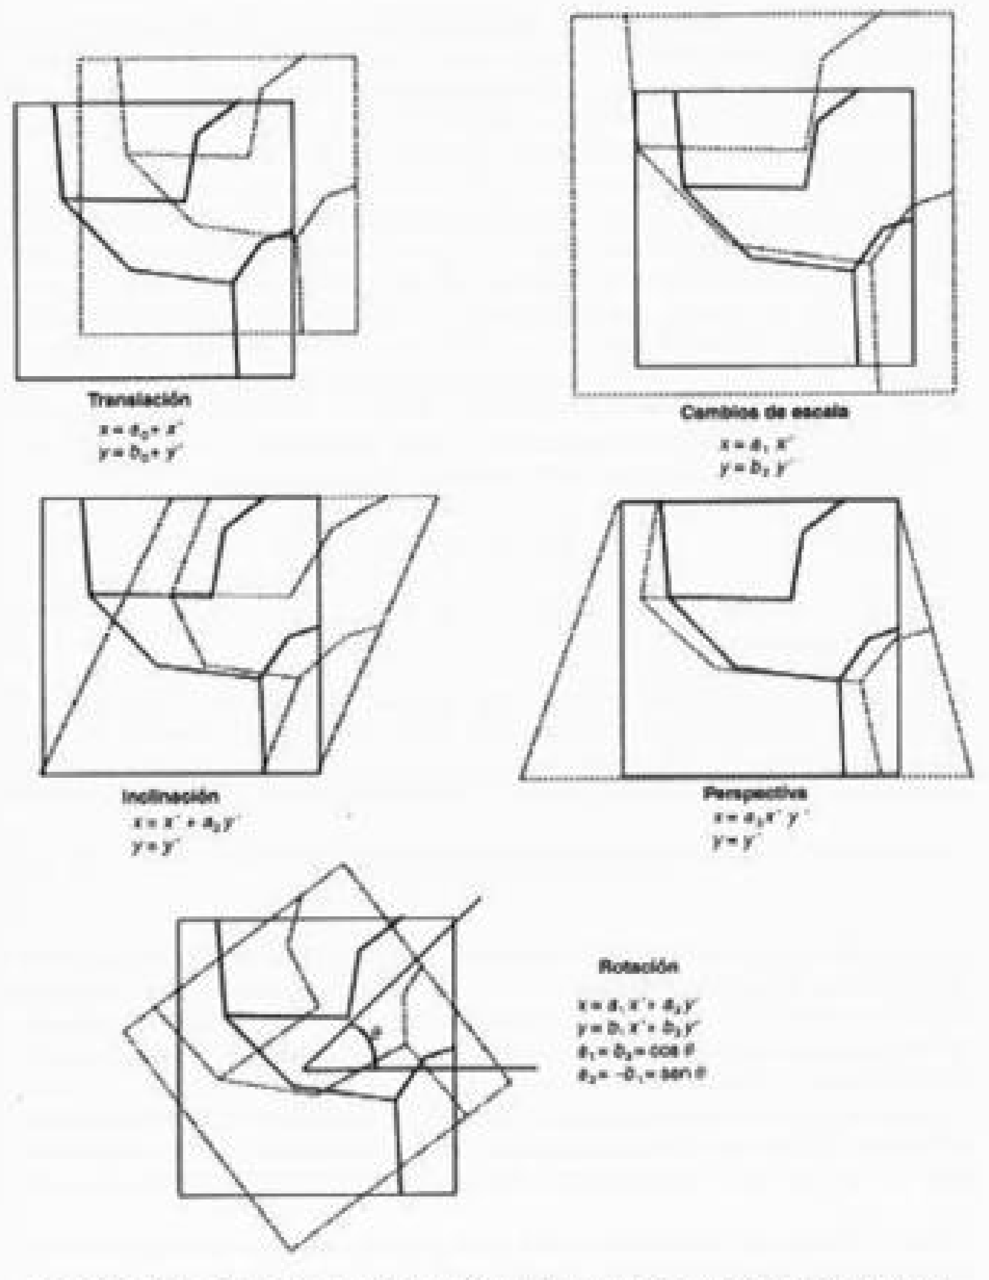


FIG. 6.52. *Ejemplos de funciones de transformación geométrica con el efecto que provocan.* (Adaptado de Schowengerdt, 1983.)

Los coeficientes de las funciones de transformación (a_0, a_1, a_2, etc.) se calculan a partir de las coordenadas de los puntos de control seleccionados previamente. El método más habitual para obtenerlos es aplicar un ajuste por mínimos cuadrados, con operaciones de cálculo idénticas a las que requiere una regresión múltiple convencional (Estébanez y Bradshaw, 1978; Snedecor y Cochran, 1980).

La bondad del grado de ajuste conseguido se mide por la importancia de los residuales. Como es bien sabido, el residual de la regresión es la diferencia entre el valor estimado y el observado, para cada uno de los puntos muestrales empleados en el proceso. Cuanto mayor sea ese valor, el ajuste entre las variables independiente y dependiente es menor. En nuestro caso, la calidad de la corrección geométrica puede valorarse comparando, para cada punto de control, las coordenadas estimadas por la regresión con las reales. El promedio de los residuales habitualmente se conoce como error medio cuadrático (*Root Mean Squared Error*, RMSE). El RMSE se calcula como la raíz cuadrada de las desviaciones entre los valores observados y los estimados por la regresión, tanto para filas como para columnas. En nuestro caso:

$$\mathrm{RMSE} = \sqrt{\frac{\sum_{i=1,n}\left((\hat{c}-c_i)^2 + (\hat{l}_i - l_i)^2\right)}{n}} \qquad [6.66]$$

También puede calcularse el RMSE para cada punto, simplemente como la raíz de los residuales al cuadrado para ese punto. Ese valor no es más que la distancia entre sus coordenadas reales y las estimadas por la regresión (fig. 6.53). En consecuencia, podemos utilizar el término error longitudinal *(EL)* para referirnos al RMSE de un punto concreto:

$$\mathrm{EL} = \sqrt{(\hat{c}_i - c_i)^2 + (\hat{l}_i - l_i)^2} \qquad [6.67]$$

Empleando este término puede resolverse una frecuente confusión que considera al RMSE como sólo aplicable al conjunto de los puntos (por el término, error medio), y no a cada punto individualmente. Además, es más acorde con la variable que estamos estimando (posición) y con el tipo de errores que cometemos (distancia al punto observado).

La calidad general del ajuste se evalúa a través del RMSE o del valor de los EL para cada punto. Si el promedio supera un cierto valor previamente indicado (habitualmente igual o inferior a 1 píxel) será necesario aplicar alguna de las siguientes soluciones:

1. Verificar las coordenadas de los puntos introducidos, revisando que tanto las coordenadas de la imagen como las del mapa sean precisas. En esta fase puede ser conveniente anotar el grado de confianza que nos merece ese punto, según la seguridad que tengamos en su correcta localización.
2. Si una vez verificadas las coordenadas se mantiene un alto RMSE, puede ser conveniente eliminar algún punto con mayor tasa de error, siempre que se trate de los catalogados como de dudosa fiabilidad, o se sitúe sobre un área próxima a otros puntos incluidos en la ecuación, lo que permitirá mantener ese sector en el ajuste final. Eliminar

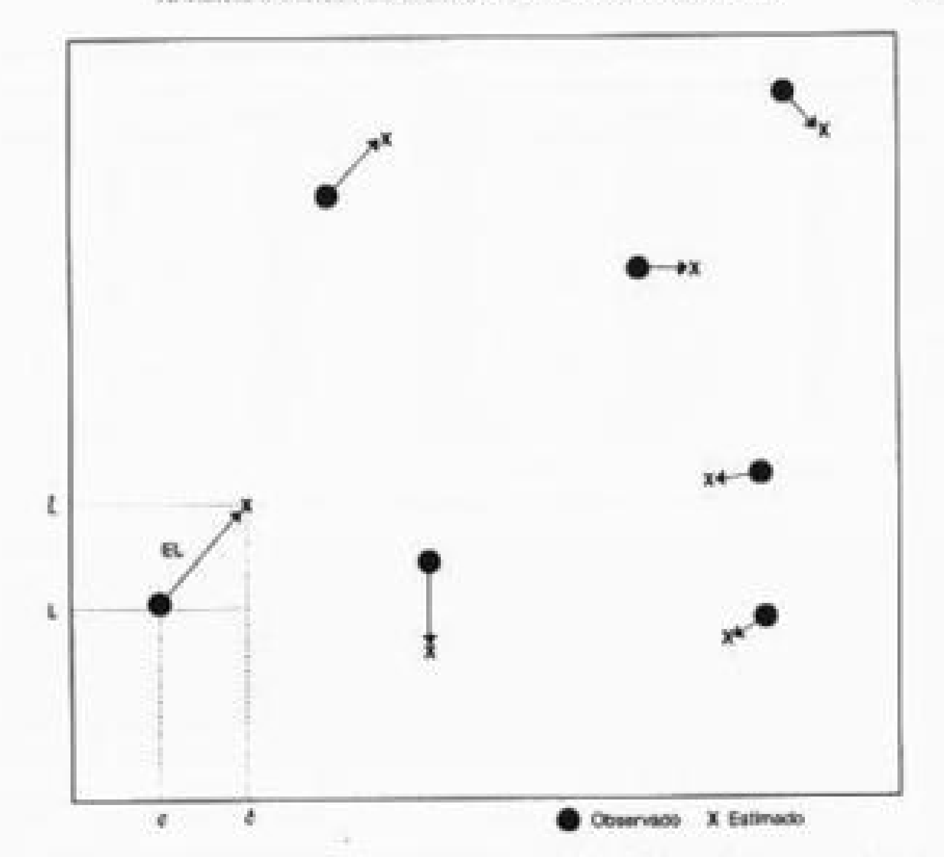


FIG. 6.53. *El error longitudinal indica la distancia entre la posición real de un punto de control y la estimada por la ecuación de ajuste.*

un punto de un sector poco representado puede suponer una reducción artificiosa del error, que luego se manifieste en sectores de la imagen que estarán mal referenciados.

3. También podemos optar por incrementar el orden del polinomio, en caso de que las deformaciones de la imagen sean muy severas, por ejemplo en terrenos quebrados. Esta solución debe tomarse con cautela, especialmente cuando el número de puntos sea pequeño, ya que se puede obtener un «sobre-ajuste» a esas zonas, introduciendo errores notables en otras poco representadas, aun cuando los residuales sean bajos (Richards, 1993, pp. 67-70).

Por ésta y otras razones, para verificar adecuadamente la corrección geométrica es necesario introducir puntos de verificación, que no se hayan utilizado en el cálculo de la ecuación de ajuste, y permitan estimar el RMSE real obtenido en el proceso. Esto permitiría evitar el sesgo que una incorrecta distribución de puntos pudiera presentar, ya que se evalúa el error, no sobre los puntos muestrales, sino sobre otros adquiridos de modo independiente al ajuste.

Para la corrección de la imagen Madrid92, teniendo en cuenta la ausencia de relieves importantes en la escena, se optó por elegir una ecuación de ajuste de primer

TABLA 6.6. *Coordenadas de los puntos de control utilizados para corregir la imagen Madrid92*

Número	*X-mapa*	*Y-mapa*	*Columna*	*Fila*
1	452.450	4.480.500	992	102
2	450.300	4.478.100	936	195
3	448.500	4.471.100	923	431
4	444.750	4.469.800	810	498
5	440.300	4.472.100	651	453
6	441.500	4.477.750	653	264
7	443.050	4.481.950	677	117
8	436.125	4.479.900	464	230
9	429.550	4.483.050	227	165
10	428.150	4.472.750	253	512
11	432.900	4.469.450	428	591

grado, con un RMSE no superior a 1 píxel (30 m). A partir de los 11 puntos de control seleccionados previamente (tabla 6.6) se obtuvieron unas funciones iniciales de transformación. El estudio de los residuales y los *EL* de cada punto nos permitió observar errores excesivos en la localización de algunos de ellos (tabla 6.7), ofreciéndose un RMSE excesivamente elevado (2,13 píxeles). Tras verificar las coordenadas se optó también por eliminar dos puntos que parecían algo más conflictivos. Con los nueve puntos resultantes se obtuvieron las siguientes ecuaciones.

$$\hat{c} = 15.177{,}79 + 0{,}032452\,X - 0{,}006443\,Y \qquad [6.68]$$

$$\hat{l} = 147.365{,}5 - 0{,}006590\,X - 0{,}032202\,Y \qquad [6.69]$$

que ofrecieron un ajuste bastante adecuado, con un RMSE de 0,76. Esto supone un error estimado en las distancias de 22,8 m, aceptable para nuestros propósitos. La tabla 6.8 recoge los residuales finales.

TABLA 6.7. *Residuales de la primera corrección (todos ellos en píxeles)*

Número	*Columna*	*Columna estimada*	*Residual columna*	*Fila*	*Fila estimada*	*Residual fila*	*EL*
1	992	990,65	1,35	102	102,16	–0,16	1,36
2	936	936,54	–0,54	195	194,15	0,85	1,00
3	923	924,16	–1,16	431	433,48	–2,48	2,74
4	810	810,75	–0,75	498	500,08	–2,08	2,21
5	651	650,81	–0,19	456	454,14	1,86	1,87
6	652	652,57	–0,57	264	262,61	1,39	1,50
7	677	675,29	1,71	116	115,97	0,03	1,71
8	463	463,53	–0,53	230	227,55	2,45	2,51
9	227	228,86	–1,86	165	167,75	–2,75	3,32
10	253	251,27	–1,73	510	511,80	–1,80	2,50
11	428	427,56	0,44	591	588,32	2,68	2,72

TABLA 6.8. *Residuales de la segunda corrección*

Número	*Columna*	*Columna estimada*	*Residual columna*	*Fila*	*Fila estimada*	*Residual fila*	*EL*
1	992	990,96	1,04	102	102,60	–0,60	1,20
2	936	936,65	–0,65	195	194,05	0,95	1,15
3	923	923,34	–0,34	431	431,33	–0,33	0,47
4	810	810,02	–0,02	498	497,90	0,10	0,10
5	651	650,79	0,21	453	453,16	–0,16	0,27
6	653	653,33	–0,33	264	263,31	0,69	0,76
7	677	676,56	0,44	117	117,85	–0,85	0,95
8	464	465,04	–1,04	230	229,50	0,50	1,16
10	253	252,31	0,69	512	512,30	–0,30	0,75

6.3.3.3. Transferencia de los ND originales a la posición corregida

Las funciones antes analizadas permiten traducir coordenadas del mapa a la imagen. Ahora bien, si pretende crearse una imagen que se corresponda adecuadamente con esas coordenadas resulta necesario trasvasar, de alguna forma, los ND de la imagen original a esa nueva posición. Las funciones de ajuste permiten calcular la posición correcta de cada píxel, pero no originan de suyo una nueva imagen, puesto que suponen sólo un trasvase de coordenadas y no de ND. Dicho de otro modo, con estas funciones de transformación puede crearse una nueva matriz, correctamente posicionada, pero vacía. El «llenado» de esta matriz es, precisamente, el objetivo de la última fase de la corrección geométrica.

El problema resulta más complejo de lo que pudiera pensarse a primera vista. Idealmente, cada píxel de la imagen corregida debería corresponderse a un solo píxel en la original. Lo normal es que no sea así, sino que el píxel de la nueva imagen se sitúe entre varios de la original (fig. 6.54), ya que este proceso supone una alteración considerable de la geometría original de la escena. Por otra parte, puede variarse también el tamaño del píxel en la imagen corregida, haciendo aún más complejo encontrar el ND que mejor exprese el valor radiométrico detectado por el sensor para esa posición.

El trasvase de ND a las coordenadas cartográficas de interés puede abordarse por tres métodos: 1) vecino más próximo, 2) interpolación bilineal, y 3) convolución cúbica. Simplificando las cosas pueden resumirse en dos, según almacenen un ND de la imagen original o lo obtengan mediante una interpolación de varios ND originales.

El método del vecino más próximo *(nearest neighbour)* se basa en situar en cada celdilla de la imagen corregida el ND del píxel más cercano en la imagen original. Ésta es la solución más rápida y la que supone menor transformación de los ND originales. Su principal inconveniente radica en la distorsión que introduce en rasgos lineales de la imagen (fallas, carreteras o caminos), que pueden aparecer en la corregida como líneas quebradas) (figs. 6.55 y 6.56).

La interpolación bilineal *(bilinear interpolation)* supone promediar el ND de los cuatro píxeles más cercanos en la original. Este promedio se pondera según la distancia del píxel original al corregido: tienen una mayor influencia aquellos píxeles más

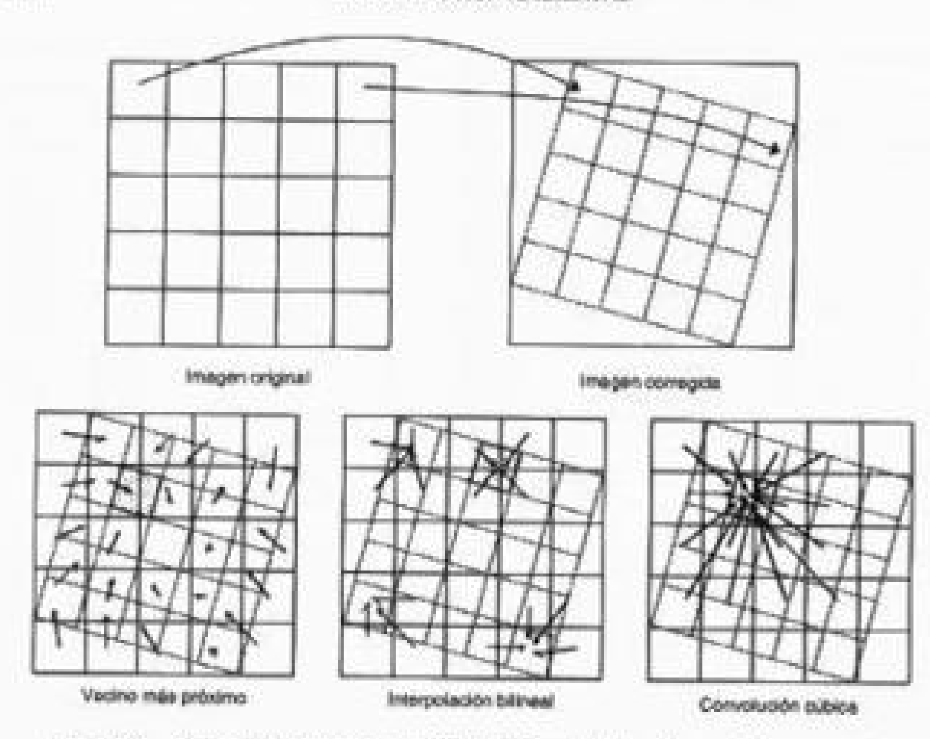


FIG. 6.54. *Procedimiento para transferir los ND originales a la posición corregida.*

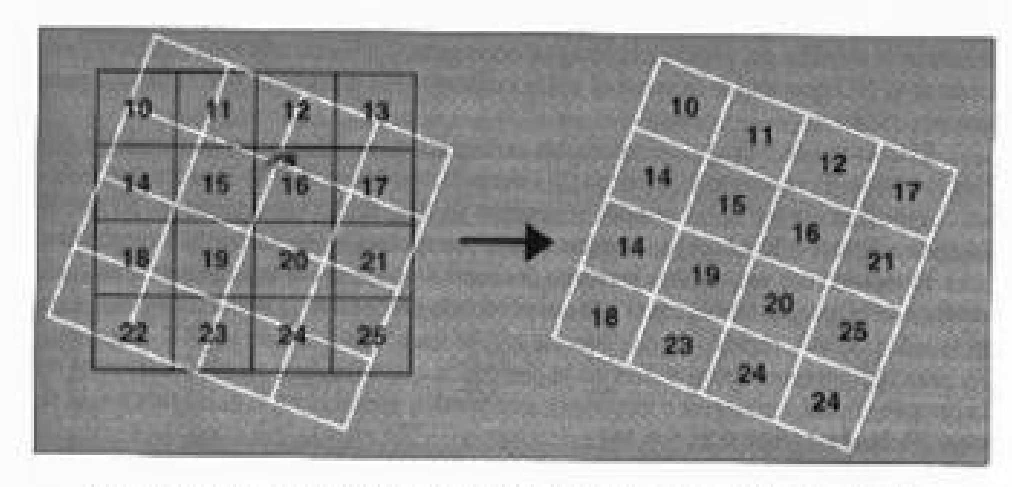


FIG. 6.55. *En el criterio del vecino más próximo pueden aparecer líneas quebradas, al rotarse los ejes de la imagen con el proceso de georreferenciación.*

cercanos en la imagen inicial. Reduce el efecto de distorsión en rasgos lineales, pero tiende a difuminar un tanto los contrastes espaciales de la imagen original.

Por último, la convolución cúbica *(cubic convolution)* considera los ND de los 16 píxeles más próximos. El efecto visual es más correcto, pero supone un volumen de cálculo mucho más elevado.

La elección entre uno de los tres métodos depende de la finalidad del proceso y de los recursos informáticos disponibles. Si pretende corregirse una imagen clasificada, el método del vecino más próximo es la elección obligada, pues es el único que preserva los valores originales al no introducir promedios (que, por otra parte, no tendrían sentido en una clasificación temática). Si, por el contrario, se pretende facilitar el análisis visual, habrá de optarse por algoritmos de interpolación más elaborados, concretamente por el de convolución cúbica si se cuenta con los recursos informáticos apropiados.

El efecto causado por estos tres métodos de trasvasar los ND a la imagen corregida se observa en la figura 6.56, correspondiente a la banda 4 de la imagen Torrel00. Resulta evidente la deformación introducida por el vecino más próximo en el embalse de Santillana y en la carretera que une Colmenar Viejo y Soto del Real. Como puede observarse, la diferencias visuales entre la interpolación bilineal o cúbica son apenas perceptibles.

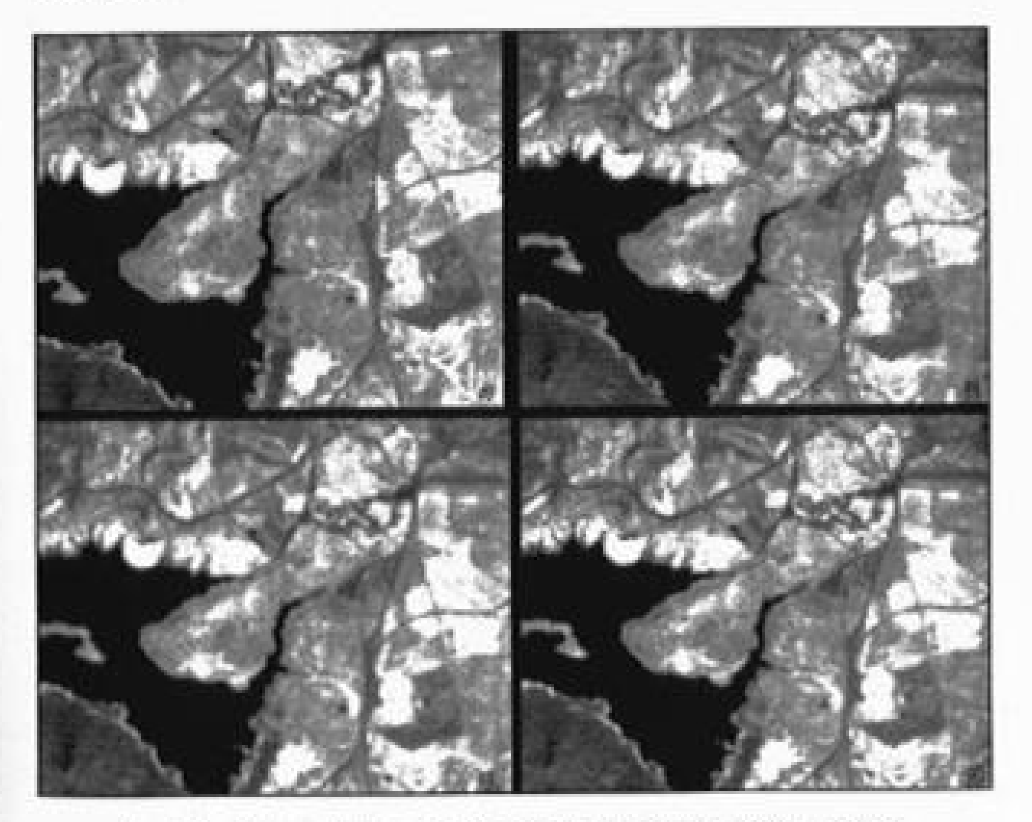


FIG. 6.56. *Criterios de interpolación para la banda 4 de Torrel00: a) original, b) vecino más próximo; c) interpolación bilineal; d) convolución cúbica.*

Para ilustrar con un ejemplo concreto la operación que realizan estos métodos de trasvase de ND podemos comentar el proceso que se seguiría para obtener los ND de una imagen por el vecino más próximo y por interpolación bilineal. El ejemplo está tomado de la imagen Madrid92, para la que antes hemos indicado las ecuaciones de ajuste [6.68 y 6.69].

En primer lugar, el intérprete tiene que definir el área sobre la que se va a aplicar el proceso. Para ello necesita introducir al ordenador o bien las coordenadas UTM $(X, Y)^7$ de los vértices y el tamaño del píxel en X, Y, o bien las coordenadas de los vértices y el tamaño de la imagen en columnas y líneas. En el primer caso se calcula el tamaño de la imagen dividiendo la diferencia de coordenadas entre el tamaño del píxel, y en el segundo se obtiene el tamaño del píxel dividiendo la diferencia de coordenadas entre el número de filas y columnas. Habitualmente se emplea la primera opción. En nuestro ejemplo se indicaron las siguientes coordenadas de los vértices NW (434.000, 4.480.000) y SE (449.000, 4.470.000), y como tamaño del píxel de salida 50 × 50 m.

Con estos datos, el programa opera de la forma siguiente:

1. Estima las coordenadas, en columnas y líneas, de los vértices de la imagen corregida, a partir de las ecuaciones de ajuste antes obtenidas [6.68 y 6.69]. Suele comenzarse por el vértice NW, puesto que resulta el origen de la nueva imagen, usando las funciones ajustadas previamente:

$$\hat{c} = 15.177{,}79 + 0{,}032452 \times 434.000 - 0{,}006443 \times 4.480.000 = 397{,}38$$
$$\hat{l} = 147.365{,}50 - 0{,}006590 \times 434.000 - 0{,}032202 \times 4.480.000 = 240{,}48$$

2. La columna y línea estimada por el ajuste sirve para extraer el ND que vamos a situar en la posición 434.000 y 4.480.000. Si utilizamos el criterio del vecino más próximo, ese ND correspondería al del píxel situado en la columna 397 y línea 240 de la imagen original (los enteros más cercanos a los valores estimados por las ecuaciones). En caso de que utilizáramos la interpolación bilineal, el ND se obtendría por un producto ponderado de los cuatro más cercanos, de acuerdo a la siguiente fórmula:

$$ND_{sal} = \frac{\sum_{i=1,4}(ND_i / D_i^2)}{\sum_{i=1,4}(1 / D_i^2)} \quad [6.70]$$

donde D_i indica la distancia entre el píxel i y el que pretende interpolarse. En nuestro ejemplo, el ND asignado a la posición 434.000 y 4.480.000 sería un promedio ponderado de los ND correspondientes a los píxeles 397-240, 397-241, 398-240 y 398-241. La distancia D se calcularía a partir de:

$$D = \sqrt{\Delta x^2 + \Delta y^2} \quad [6.71]$$

7. Para evitar malinterpretaciones, cuando indicamos las coordenadas UTM de un determinado píxel nos referimos a las coordenadas de su punto central.

donde ΔX y ΔY son las diferencias entre el valor estimado y el original en columna y línea, respectivamente. Por ejemplo, para el píxel situado en las coordenadas 397-240, $\Delta X = 0{,}38$ y $\Delta Y = 0{,}48$, luego $D = 0{,}612$. En consecuencia, ese píxel tendría más peso en el cálculo que el situado en 398-241, que contaría con una distancia de $D = 0{,}80$.

3. El resto de los ND de la imagen se obtienen de forma similar al indicado. Conociendo las coordenadas UTM del vértice NW de la zona y el tamaño del píxel, pueden irse calculando las coordenadas UTM del área que pretende «llenarse» con ND de la imagen original. Basta añadir a la coordenada X del vértice NW los 50 m de separación entre píxeles para obtener la siguiente coordenada X. En el caso de la coordenada Y, en lugar de sumar hay que restar el tamaño del píxel para obtener la siguiente fila de la imagen corregida, ya que las coordenadas en Y decrecen de norte a sur. Una vez calculadas las coordenadas UTM se introducen en las ecuaciones arriba indicadas, obteniendo la columna y fila estimada para tales coordenadas. A partir de esos valores estimados puede obtenerse el ND correspondiente a esas coordenadas. Por ejemplo, el píxel situado en la columna 220 y línea 165 de la imagen de salida tendrá las siguientes coordenadas UTM:

$$X(220{,}165) = 434.000 + 220 \times 50 = 445.000$$

$$Y(220{,}165) = 4.480.000 - 165 \times 50 = 4.471.750$$

A partir de esas coordenadas estimamos la localización en columna y línea de la imagen original usando [6.68 y 6.69], lo que ofrece un valor estimado de columna y línea de 807,44 y 433,66, respectivamente. De ahí deducimos que el ND del píxel 220-165 en la imagen corregida, con coordenadas UTM 445.000 y 4.471.750 tendrá asignado el ND del píxel situado en la columna 807 y línea 434 de la imagen original (empleando el criterio del vecino más próximo). Este proceso se continúa hasta que se alcanza el vértice SW de la zona designada por el usuario, momento en el cual se culmina la corrección.

El resultado final del proceso aparece en la figura 6.57. Se trata de la banda 4 de la imagen Madrid92, tras aplicar el método de interpolación bilineal. Resulta patente la transformación geométrica que ha sufrido la imagen original, especialmente en lo que se refiere a su orientación y tamaño. Las esquinas de la imagen aparecen en color negro porque sobre esa zona no se han encontrado datos para la interpolación. Esto ocurre cuando seleccionamos una ventana excesivamente pequeña en la imagen original, de tal forma que al corregirla geométricamente, hay zonas de interés que no tienen datos. Para evitar esto, siempre conviene cortar una ventana más grande del área que pretendamos estudiar, de tal forma que al georreferenciar la imagen original tengamos datos de salida en todas las zonas de interés. Así se muestra en el caso de la imagen Torrel00: al rotar la imagen con la corrección geométrica seguimos teniendo datos, pues la ventana original era mucho más grande que la zona de interés (fig. 6.58).

6.3.3.4. Corrección con modelos digitales de elevación

La corrección geométrica basada en puntos de control ha sido el procedimiento más habitual para imágenes espaciales de alta resolución, Landsat o SPOT, y es el

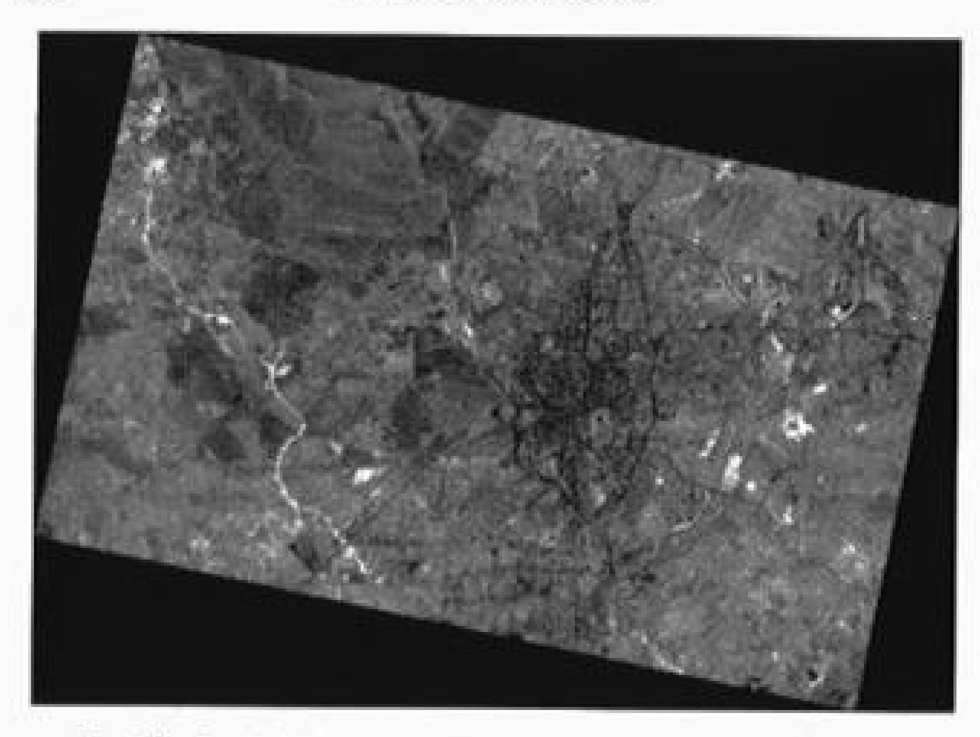


FIG. 6.57. *Banda 4 de la imagen Madrid92 georreferenciada a coordenadas UTM.*



FIG. 6.58. *Imagen Torrel00 georreferenciada a coordenadas UTM (Banda 4).*

que está disponible en la mayor parte de los programas comerciales. Los resultados son, en la mayor parte de los casos, suficientemente satisfactorios. Sin embargo, en el caso de trabajar sobre zonas con un relieve muy quebrado, o con imágenes aéreas, en donde las deformaciones geométricas están estrechamente ligadas al modelado del relieve, sería necesario acudir a la información topográfica. La creciente conexión entre la teledetección y los SIG permite abordar estas operaciones de modo cada vez más accesible. Para realizar una corrección geométrica del efecto topográfico es preciso contar, previamente, con MDE. Como ya hemos visto, los MDE son de gran interés para el cálculo de reflectividades corregidas del efecto de iluminación. En el terreno de la corrección geométrica, la introducción de los MDE implica habitualmente realizar una rectificación diferencial, en donde cada ND se transfiera separadamente desde la imagen original a la resultante a partir de corregir la posición del píxel en función del desplazamiento debido al relieve (Palà y Pons, 1995). Cada coordenada *X, Y, Z* del MDE se transforma a la imagen mediante ecuaciones colineales, interpolando el ND de la imagen a partir de uno de los métodos antes comentados (Novak, 1992). También puede simplificarse la corrección, empleando un modelo polinómico donde la altura se introduce como una nueva variable independiente (Palà y Pons, 1995):

$$\hat{z} = a_0 + a_1 X + a_2 Y + a_3 Z + a_4 ZX + A_5 ZY \qquad [6.72]$$

lo que ofrece resultados mucho mejores al ajuste lineal o cuadrático cuando el terreno es montañoso. Esta inclusión de los datos altimétricos resulta clave cuando las imágenes no se adquieren verticalmente (como puede ser el caso de las adquiridas por el SPOT), en las que los errores debidos al relieve son muy notables.

6.3.3.5. Conveniencia de las correcciones geométricas

Antes de terminar el presente epígrafe conviene hacer una breve reflexión sobre la necesidad y momento de las correcciones geométricas. Tradicionalmente esta operación se ha concebido como previa e imprescindible a cualquier análisis posterior de la imagen. En los últimos años, sin embargo, se prefiere restringir estas correcciones, relegándolas, siempre que sea posible, a la fase final del trabajo, una vez que se hayan obtenido los resultados finales de la interpretación.

La razón es doble: por un lado, se reduce el tiempo de tratamiento, pues, en lugar de corregir todas las bandas originales, basta corregir una, la que contiene la imagen resultado; por otro, se aborda la clasificación con los valores originales, evitando el efecto de promedio parejo a la tercera fase del proceso de corrección. Algunos autores han estudiado la importancia de este efecto (Smith y Kovalick, 1985). Las conclusiones de estos trabajos aconsejan realizar la clasificación con los valores originales, si bien no se encontraron grandes pérdidas de exactitud con el empleo de las imágenes corregidas.

Pese a los comentarios previos, conviene tener presente que, en determinadas aplicaciones, las correcciones resultan un paso obligado y previo a otros tratamientos. Éste es el caso de las aplicaciones cartográficas en general —y, específicamente, en lo que se refiere a la realización de mosaicos (Hord, 1982; Verhoef y Peteri, 1984)—, así como

los estudios multi-temporales o los que acudan a información auxiliar (cap. 9). En ambos casos, la exactitud en el ajuste resulta un elemento fundamental.

En resumen, puede afirmarse que las correcciones geométricas son necesarias en la mayor parte de las aplicaciones de la teledetección espacial, aunque no en todas ellas como fase previa de trabajo. Si lo que se pretende es conectar los resultados de la clasificación con otras variables geográficas, o superponer dos clasificaciones realizadas en distinta fecha, las correcciones geométricas pueden abordarse al finalizar el proceso de análisis. Ahora bien, si pretende trabajarse con valores físicos (reflectividades, temperaturas) o introducir variables o imágenes auxiliares en la clasificación, es evidente que el registro geométrico es requisito previo a otros tratamientos.

CAPÍTULO 7

ANÁLISIS DE IMÁGENES: EXTRACCIÓN DE INFORMACIÓN TEMÁTICA

«Profesor: que te ilusione hacer comprender a tus alumnos, en poco tiempo, lo que a ti te ha costado horas de estudio llegar a ver claro.»

S. JOSEMARÍA ESCRIVÁ, *Surco*

1. Generación de variables continuas

Después de comentar los diversos tratamientos que conducen a disponer los datos de forma más idónea para extraer de ellos información temática de interés dedicamos precisamente este capítulo a comentar las diversas técnicas que permiten extraer esa información de las imágenes. Hemos dividido la exposición en cuatro apartados según el objetivo principal del análisis sea la obtención de variables continuas (1), la categorización de la imagen en clases temáticas (2), el análisis de cambios (3) o la medición de la estructura espacial del territorio (4). Este capítulo se complementa con los dos siguientes, dedicados, respectivamente, a verificar los resultados (cap. 8) y a conectarlos con otras fuentes de información en el marco de los SIG (cap. 9).

1.1. TÉCNICAS DE MODELADO EN TELEDETECCIÓN

1.1.1. *Teledetección cualitativa y cuantitativa*

Es obvio que el interés de la teledetección viene dado por su capacidad de proporcionarnos información temática, que cubra vacíos en nuestro conocimiento del territorio o, al menos, actualice lo que ya se había inventariado previamente.

En muchas ocasiones se restringe el contenido informativo de la teledetección a la cartografía temática propiamente dicha. En otras palabras, las imágenes de satélite serían, bajo este punto de vista, sólo una herramienta para clasificar el territorio en categorías homogéneas, por ejemplo de cobertura del suelo, vegetación o cultivos. Con

ser de gran interés este enfoque nos parece reduccionista. Conviene no perder de vista que una imagen de satélite es un conjunto sistemático de medidas cuantitativas sobre el territorio, con un nivel de resolución espacial inalcanzable en muestreos de terreno. Si esas mediciones se relacionaran satisfactoriamente con ciertos parámetros ambientales de interés, a partir de una imagen podría obtenerse la distribución espacio-temporal de dichos parámetros. Por ejemplo, en la mayor parte de los países la observación meteorológica se realiza a partir de una serie de puntos bastante dispersos en el territorio (donde se sitúan los observatorios). A partir de las mediciones que la teledetección realiza de la temperatura del suelo disponemos de una representación mucho más exacta de cómo las temperaturas se distribuyen en el espacio, ya que una imagen incluye medidas sistemáticas sobre el territorio (cada kilómetro, aproximadamente, en el caso del sensor AVHRR). La única manera de obtener una cartografía exhaustiva del territorio a partir de sensores convencionales sería mediante técnicas de interpolación espacial (Mitas y Mitasova, 1999), que serán tanto mas certeras cuanto mayor densidad de observatorios dispongamos y el territorio sea más homogéneo. Por ejemplo, la figura 7.1 nos permite comparar una mapa de evapotranspiración (ET) del cultivo de referencia obtenido mediante interpolación espacial de 26 estaciones meteorológicas en Andalucía, con el que se obtuvo mediante regresión lineal con variables derivadas de imágenes AVHRR (Sánchez y Chuvieco, 2000). Resulta obvio el carácter mas realista de esta segunda estimación y su mejor adaptación a los rasgos del relieve regional.

Bajo esa óptica, podemos considerar la teledetección como una de las herramientas más potentes para generar información biofísica sobre el conjunto del territorio, a intervalos regulares y en condiciones comparables (sensor, altitud, hora de adquisición, etc.). Potencialmente las variables que pueden deducirse a partir de la teledetección son muy numerosas, siendo su rasgo común que están, de un modo u otro, relacionadas con las propiedades ópticas de los objetos, con su distancia al sensor o con su posición.

Podemos aquí establecer una primera distinción entre unas variables que son medibles de modo directo y otras que se derivan a partir de aquéllas. Las primeras son una función de los datos adquiridos por el sensor, por lo que pueden extraerse directamente de ellos si conocemos los parámetros de adquisición. Las más importantes son: la Reflectividad en el espectro solar (VIS, IRC, SWIR), la Temperatura en el térmico, el

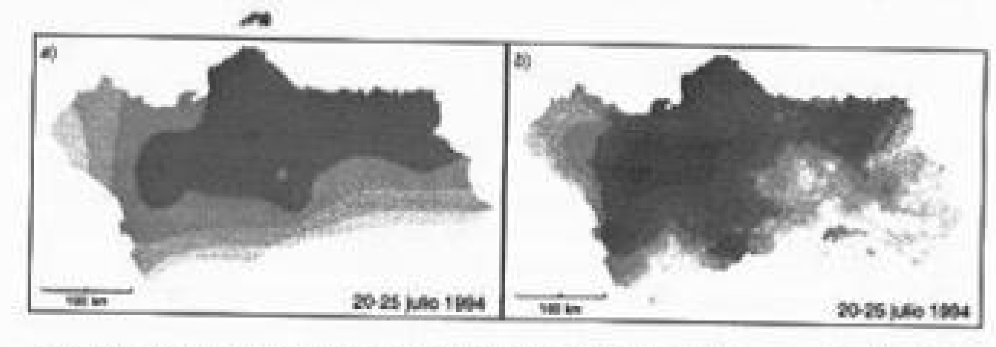


FIG. 7.1. *Mapas de ET estimada a partir de interpolación espacial (a) y regresión lineal (b) con variables derivadas de imágenes AVHRR* (Sánchez y Chuvieco, 2001).

Coeficiente de retro-dispersión (micro-ondas), la Altitud, a partir de la visión estereoscópica en el óptico, la medición de distancias con lidar y la interferometría radar, y la Topografía de la superficie marina, a partir del altímetro de micro-ondas.

En cuanto a las variables indirectas, se trata de factores que se pueden derivar de las anteriormente citadas, gracias a que suponen una modificación de la señal recibida por el sensor. Por ejemplo, el contenido de clorofila no es una variable directamente medida por el sensor, pero modifica la reflectividad que éste recibe, por lo que puede estimarse indirectamente observando en qué bandas su efecto es más evidente y aislando ese componente de otros factores que también puede influir en tales bandas. Otros ejemplos de estas variables que pueden estimarse indirectamente a partir de la teledetección son el índice de área foliar, la radiación absorbida por la planta, la humedad del suelo o de las hojas, la turbidez del agua, el contenido de CO_2 en la atmósfera, la ET o la productividad vegetal neta, entre otros que podrían citarse. Para obtener estas variables, tan críticas para un conocimiento más certero de nuestro medio ambiente, es preciso relacionarlas con la información contenida en las imágenes, estableciendo un modelo suficientemente fiable.

1.1.2. *Tipo de modelos en teledetección*

En teledetección, como en cualquier otra disciplina científica, podemos establecer una clasificación de los modelos disponibles en dos grandes categorías, según partan del diseño experimental para extraer principios teóricos a partir de él (modelos inductivos o empíricos), o propongan estimaciones a partir de analizar las relaciones teóricas entre los componentes de un determinado problema (modelos deductivos o teóricos). Las principales características de unos y otros, en el caso concreto de la teledetección, pueden resumirse como sigue (Danson *et al.*, 1995; Lillesand y Kiefer, 2000; Strahler *et al.*, 1986; Verstraete, 1994):

1. Los modelos inductivos o empíricos intentan establecer una relación numérica entre el parámetro a estimar y los valores del sensor, a partir de unas observaciones *in situ*, tomadas en el momento de adquirir la imagen. En otras palabras, se obtienen funciones de ajuste local que ponen en relación los datos de la imagen con el parámetro de interés. La técnica de ajuste más habitual es la regresión, en sus diversas variantes (Ahern *et al.*, 1991; Alonso *et al.*, 1996; Curran y Kupiec, 1995; Ji *et al.*, 1992), aunque también hay algunos ejemplos de ajustes mediante redes neuronales (Baret, 1995; Clark y Cañas, 1995; Fourty y Baret, 1997).

Las principales ventajas de los modelos empíricos son su sencillez (no requieren planteamientos *a priori* complejos) y la posibilidad de estimar su exactitud, ya que se contrastan con unas observaciones de la misma variable que se estima. Su principal inconveniente atañe a su escasa capacidad de generalización, ya que sólo podrían aplicarse con las mismas o similares condiciones a la situación en que se generaron (condiciones ambientales del lugar, sensor, rango de la variable que se estima, condiciones de observación o atmosféricas, etc.).

2. En cuanto a los modelos teóricos o deductivos, pretenden establecer relaciones de validez general, lo más independiente posible de unas determinadas condiciones de observación. Parten de demostrar la relación física entre el parámetro a estimar

(por ejemplo, contenido de clorofila, LAI o ET) y la información espectral contenida en la imagen. Una vez comprobada esa relación, con algunos ejemplos empíricos, se invierte el modelo, de tal forma que pueda estimarse esa variable a partir de las imágenes (Asrar *et al.*, 1989; Dymond *et al.*, 2001; Fourty y Baret, 1997; Jacquemoud, 1993; Zarco-Tejada *et al.*, 1999). Esto implica un proceso de ajuste que, en muchas ocasiones, resulta muy complejo y no siempre suficientemente preciso, ya que es necesario asumir condiciones que rara vez se dan en la naturaleza (p. ej., isotropía en las hojas, terreno plano, reflectividad lambertiana, etc.). Incluso aunque esta relación entre variable de interés e información espectral sea consistente, no resulta sencillo obtener esas variables espectrales, ya que es preciso eliminar de la imagen cualquier efecto extraño a la señal procedente de la cubierta. Esto implica modelar los efectos atmosféricos, la geometría de observación, el aporte del sustrato y las condiciones de mezcla con otras cubiertas, por citar sólo los más significativos. No obstante, y pese a las dificultades que presenta, el modelado deductivo resulta un camino mucho más firme que el inductivo para estimar variables biofísicas a partir de la teledetección, ya que facilita un mejor entendimiento de las variables que están influyendo en el proceso, además de requerir menos información colateral (trabajo de campo), simultánea a la adquisición, que sólo estará disponible cuando se haya planificado previamente un experimento con ese objetivo.

3. Algunos autores plantean una alternativa intermedia, que denominan modelos semi-empíricos, en donde se asume un previo modelado de la variable a estimar, aunque el ajuste se realice por ecuaciones empíricas. También se asigna esta denominación cuando los ajustes locales se basan sobre variables derivadas, como es el caso de los índices de vegetación (1.2), que ya cuenten con una relación teórica demostrada con las variables que pretenden estimarse (Danson *et al.*, 1995).

Como ilustración de estas ideas vamos a revisar dos ejemplos de los distintos tipos de modelado que pueden realizarse en teledetección, empírico y teórico, utilizando como caso de estudio la estimación de la misma variable: el contenido de agua en la vegetación.

1.1.3. *La estimación empírica del contenido de agua en las plantas*

Los modelos empíricos tienen una larga tradición en la investigación científica. Como es lógico, aunque se trata de ajustes locales, adaptados a las condiciones concretas que se miden, deben también tener una base física, ya que es necesario que las relaciones que se propongan estén apoyadas en un fundamento sólido. Como decíamos antes, este tipo de modelado tiene las ventajas de ofrecer una evaluación numérica de la precisión alcanzada en el modelo, ya que se pone en relación con datos medidos experimentalmente, además de ser relativamente sencillos de calibrar. Entre sus inconvenientes figura, por un lado, la complejidad de realizar las mediciones (especialmente cuando hablamos del trabajo de campo), y, por otro, el escaso carácter generalizador de los resultados. No obstante, cuando el modelo empírico está bien fundamentado, la calibración en diversos lugares permite finalmente plantear funciones mas generalistas, que pueden llegar a considerarse de validez global. Por ejemplo, el índice de peligro de incendios utilizado por el Servicio Forestal Canadiense (*Fire Weather Index*: Van Wagner, 1974) tiene un desarrollo fundamentalmente empírico y está calibrado

para las condiciones canadienses. Sin embargo, y hasta cierto punto sorprendentemente, funciona muy bien en otros entornos ambientales muy distintos al canadiense, por lo que se está empleando operativamente en lugares tan diversos como Indonesia y la cuenca mediterránea europea.

Presentamos como ejemplo de cómo plantear este tipo de modelos empíricos la estimación del contenido de agua en las plantas. Nuestro departamento ha dedicado un considerable esfuerzo en los últimos cinco años a esta tarea, intentando entender mejor las relaciones entre la reflectividad y temperatura estimadas por teledetección y la dinámica del contenido de agua en las principales formaciones vegetales del mundo mediterráneo (pastizales y matorral), de cara a mejorar los sistemas actuales de prevención del peligro de incendio. Con este objetivo en mente hemos tomado muestras sistemáticas en el terreno para la primavera y el verano del período comprendido entre 1996 y 2001. Las muestras se han tomado siguiendo un estricto protocolo (Desbois *et al.*, 1997*a*), de tal manera que las series fueran comparables en el tiempo. La primera dificultad que se planteó en el estudio fue la elección del área de muestreo, ya que se requería contar con una zona relativamente plana y con suficiente homogeneidad para realizar estimaciones consistentes a partir de imágenes de baja resolución espacial (concretamente AVHRR y Vegetation). Esto implicaba contar con grandes extensiones (entre 4 y 9 km^2) de cubierta relativamente uniforme, lo cual resultaba bastante complicado en un espacio tan heterogéneo como el mediterráneo. Por otra parte, esas superficies deberían cubrirse principalmente con pastizal y matorral, sin mezcla de terrenos cultivados, que modifican drásticamente la señal entre la primavera y el verano (después de la recolección). Afortunadamente, contamos con el apoyo de las autoridades del Parque Nacional de Cabañeros, que reunía las condiciones idóneas para este estudio, tanto desde el punto de vista topográfico como de cubiertas vegetales.

Otro problema que se planteaba, y que puede ser común a otros estudios empíricos es la adecuada selección en terreno de las parcelas, de tal forma que sean suficientemente representativas del área observada por el sensor, por un lado, y sean manejables, por otro. Recoger información exhaustiva y repetitiva de una parcela de 9 km^2, por ejemplo, resulta inabordable en terreno, por lo que es necesario aplicar algún criterio de muestreo que permita obtener medidas suficientemente significativas. En nuestro caso se acotaron 3 parcelas para pastizal, a una distancia entre ellas de unos 5 km, y otras 2 para matorral, separadas unos 4 km. Las diferencias encontradas en la variación temporal del contenido de agua entre parcelas de la misma especie vegetal son prácticamente despreciables, lo que indica que los datos tomados en campo recogen adecuadamente las tendencias de las distintas especies que estamos analizando en el área de estudio.

El muestreo se realizó a intervalos regulares (cada 8 días) coincidiendo los días con la adquisición del Landsat, y la hora de recolección con el paso del satélite NOAA. Como es lógico, en cualquier modelado empírico es importante que los datos de campo se tomen simultáneamente a la adquisición de las imágenes, siendo el requisito tanto más estricto cuanto mayor dinamismo tenga la variable. En nuestro caso, el contenido de agua en las plantas presenta una cierta inercia temporal (Brown *et al.*, 1989; Weber y Ustin, 1991), por lo que resultaba aceptable realizar simultáneamente el muestreo para correlacionar con datos Landsat-TM, SPOT-Vegetation y NOAA-AVHRR, pese a que las imágenes se toman con 3-4 horas de diferencia.

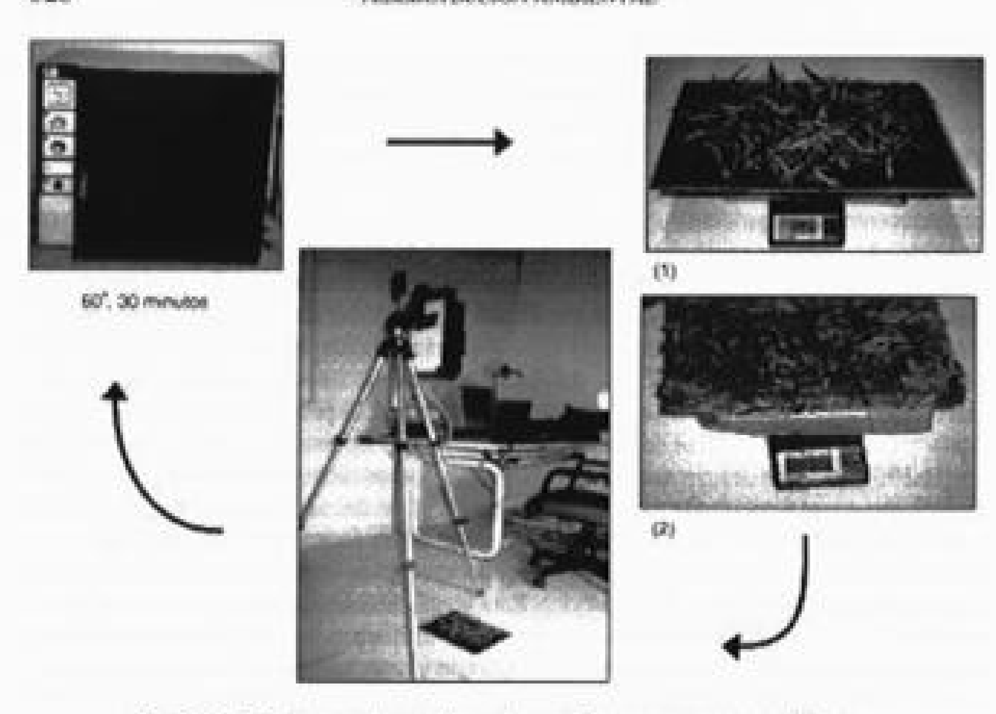


FIG. 7.2. *Diseño experimental para las medidas con espectro-radiómetro. La muestra se pesaba y medía a intervalos regulares de secado.*

Junto a los datos de campo, un modelo empírico precisa una buena fundamentación teórica y un sustento en observaciones espectrales controladas. En nuestro caso, la bibliografía sobre relaciones entre contenido de agua y reflectividad es muy amplia,[1] resumiéndose en el interés de las bandas del SWIR para una estimación directa, y las del IRC e IRT para una estimación indirecta, no válida en todas las especies (Bowman, 1989; Carter, 1991; Cohen, 1991; Gao, 1996; Jackson *et al.*, 1986; Leblon, 2001; Moran *et al.*, 1994). Los resultados con sensores de micro-ondas no son todavía muy concluyentes (Leblon, 2001; Moghaddam y Saatchi, 1999; Paloscia y Pampoloni, 1984). Para confirmar las experiencias de otros autores o matizarlas para las especies mediterráneas bien adaptadas a la sequía estival nos pareció oportuno realizar algunos análisis sobre las variaciones de reflectividad en espectros continuos para distintos niveles de contenido de humedad y diversas especies. Se realizaron diversas campañas de medición con un espectro-radiómetro GER 2600, capaz de observar un espectro continuo de 512 bandas en el rango de 0,4 a 2,5 μm. Se tomaron medidas de diversas especies de matorral y pastizales, utilizando bandejas de hojas con una geometría constante a lo largo de todo el experimento (fig. 7.2), para evitar efectos incontrolados de otros parámetros, como cambios en la morfología de las hojas, que suelen acompañar a la pérdida de humedad en algunas especies (Jackson y Ezra, 1985). Los análisis de las curvas espectrales para distintos contenidos de humedad de la misma especie permitieron observar cuáles eran las bandas más sensibles a esta variable, confirmando el gran interés de la región del SWIR para estos estudios (fig. 7.3: Vaughan, 2001).

1. Los trabajos de Riaño *et al.* (2000), Leblon (2001) y Ceccato *et al.* (2001) incluyen una amplia revisión bibliográfica sobre este tema.

Sobre esta base se planteó el análisis empírico que consistió en realizar ajustes de regresión entre los datos de campo y las variables derivadas de teledetección. Como hemos dicho, se emplearon datos del TM, Vegetation y AVHRR (Chuvieco *et al.*, 2001). El primero tiene la ventaja de ofrecer canales ópticos y térmicos, con dos bandas en el SWIR, buena resolución espacial y consistencia radiométrica, pero el inconveniente de su alto coste y baja resolución temporal. El segundo ofrece buena resolución temporal, coste intermedio y una banda en el SWIR, aunque no en el térmico. El tercero es de libre adquisición (nuestro propio departamento tiene instalado un sistema de recepción), y cuenta con buena resolución temporal y espectral, con la salvedad de no tener una banda en el SWIR hasta el lanzamiento del NOAA-15 (en 1998); además, es poco consistente en las series temporales, por el problema de los variados ángulos de observación que vimos anteriormente (cap. 6, apdo. 6.2.3.4).

Un ejemplo de las correlaciones empíricas obtenidas, para el caso de las imágenes AVHRR en el año 1999, se incluyen en la tabla 7.1 (Cocero *et al.*, 2000). Esos datos permiten confirmar las hipótesis planteadas en cuanto a la relación entre las variables de satélite y la dinámica del contenido de humedad (CH). A continuación planteamos un modelo de regresión utilizando las variables más significativas. Como ejemplo de estos ajustes presentamos uno generado para el período estival (junio a septiembre) con datos AVHRR. Se emplearon 2 años consecutivos de datos para el ajuste (1996 y 1997), y otros dos para la validación (1998 y 1999). La ecuación planteada incluía especies de matorral y pastizal (Chuvieco *et al.*, 2002*a*):

$$SCH = -21{,}032 + 11{,}504 \cdot NDVI/TS + 0{,}8297 \cdot GR \qquad [7.1]$$

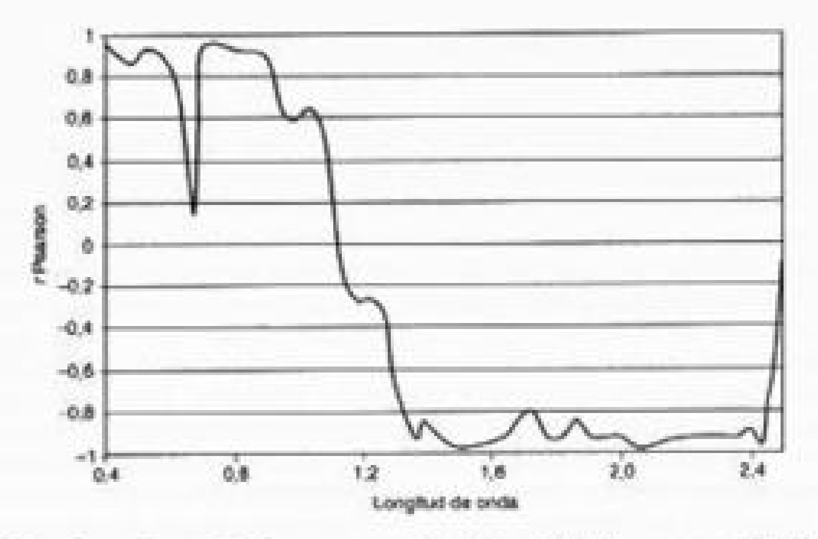


FIG. 7.3. *Curvas de correlación entre contenido de humedad del romero y su reflectividad para distintas longitudes de onda.* (Vaughan, 2001.)

TABLA 7.1. *Correlación de Pearson entre el CH y los derivados de las imágenes del satélite NOAA-AVHRR para la primavera y el verano de 1999* (Cocero *et al.*, 2000)

	TS	*NDVI*	*TS-TA*	*SAVI*	*GEMI*	*SM*	*NDVI/TS*
Pasto (1)	–0,65	0,76	–0,56	0,83	0,81	0,76	0,74
Pasto (2)	–0,70	0,78	–0,59	0,89	0,89	0,82	0,78
Pasto (3)	–0,67	0,78	–0,55	0,82	0,83	0,82	0,78
Pasto (promedio)	–0,66	0,75	–0,55	0,82	0,81	0,77	0,75
Brezo (4)	–0,77	0,50	–0,59	0,74	0,72	0,56	0,69
Jara N. (4)	–0,87	0,55	–0,82	0,72	0,71	0,70	0,85
Jara V. (4)	–0,81	0,80	–0,70	0,84	0,79	0,89	0,93
Romero (4)	–0,93	0,66	–0,79	0,74	0,70	0,78	0,93
Labiérnago (4)	–0,85	0,50	–0,71	0,60	0,57	0,71	0,82
Brezo	–0,85	0,69	–0,73	0,69	0,59	0,77	0,83
Jara N. (5)	–0,78	0,53	–0,70	0,52	0,44	0,64	0,77
Jara V. (5)	–0,75	0,28	–0,71	0,43	0,31	0,79	0,75
Romero	–0,93	0,62	–0,77	0,55	0,46	0,71	0,92
Labiérnago (5)	–0,86	0,46	–0,71	0,51	0,43	0,60	0,80
Matorral (promedio)	–0,88	0,66	–0,76	0,71	0,65	0,77	0,88
Quejigo (6)	–0,84	0,69	–0,63	0,50	0,37	0,65	0,88

* Las correlaciones significativas al nivel 0,01 aparecen en *cursiva*. Entre paréntesis se indica el número de la parcela en el terreno. El significado de los acrónimos figura en el anexo 3.

donde SCH es el contenido de humedad estimado para pasto y matorral, NDVI un índice de vegetación que comentaremos en el próximo apartado, *TS* la temperatura de Superficie, y *GR* un índice de verdor, que expresa la relación entre el NDVI de un momento determinado y los límites máximos y mínimos que se han observado en la misma zona. El ajuste encontrado ofreció un coeficiente de correlación de Pearson de 0,683 (significación < 0,001). La ecuación fue validada con los otros dos años de muestras en terreno (1998 y 1999), obteniéndose una buena estimación ($r = 0{,}804$). La figura 7.4 permite observar el grado de ajuste entre las tendencias observadas (CH) y estimadas (SCH) para el pastizal y matorral en los dos años de validación. Además de en este área de estudio, el modelo se ha verificado en otros lugares mediterráneos (el sur de Francia y Andalucía), obteniéndose también ajustes razonables (Chuvieco *et al.*, 2002*a*).

1.1.4. *Modelado teórico: estimación del contenido de agua a partir de la simulación de la señal*

La alternativa a los ajustes empíricos se basa en la aplicación de modelos físicos o matemáticos, que permitan estimar los parámetros de interés a partir de los datos adquiridos mediante teledetección. Se basan en el análisis de los factores físicos que intervienen en los procesos de reflexión, absorción y dispersión de la radiación incidente, planteando métodos para estimar la reflectividad global observada por el sensor a partir de una serie de parámetros de entrada (propiedades ópticas de las hojas, arquitectura del dosel, ángulos de observación, etc.). Suponiendo que esa estimación de la reflectividad sea correcta, el reto posterior sería invertir los modelos propuestos, de tal

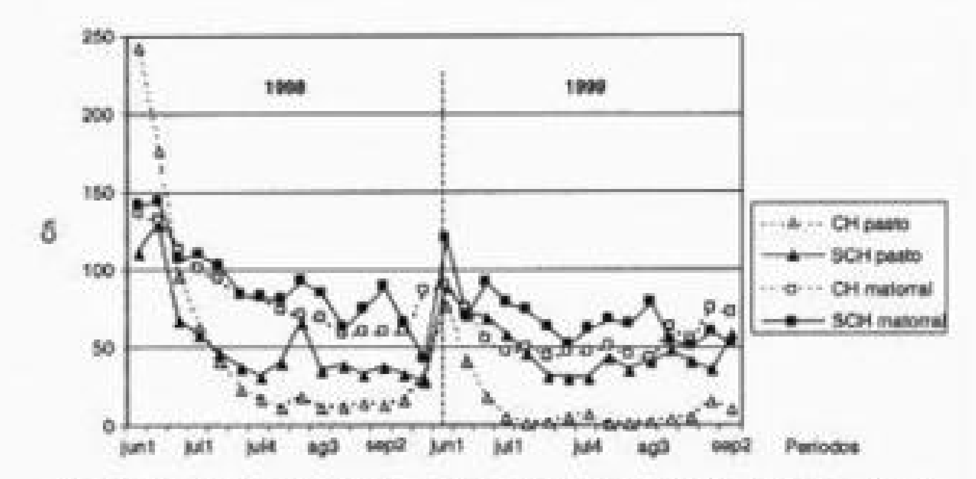


FIG. 7.4. *Ajuste entre valores observados y predecidos para la estimación del contenido de humedad (CH).* (Chuvieco *et al.*, 2002.)

manera que pudieran estimarse esos parámetros a partir de la reflectividad medida por el sensor. En el ejemplo que venimos comentando, se trataría de estimar, en primer lugar, el efecto del contenido de agua de la planta sobre la reflectividad del dosel vegetal, mezclando su contribución con la de otros factores (como puede ser la clorofila o la cantidad de materia seca). En un segundo paso se trataría de invertir el modelo, aislando de la reflectividad disponible en la imagen el componente de contenido de agua. La operatividad de este método frente a los ajustes empíricos dependerá de tres factores: contar con un buen modelo, con un buen método de inversión y con reflectividades calibradas (Jacquemoud *et al.*, 2000). Por un buen modelo nos referimos a que sea preciso, a que no requiera parámetros de entrada de muy difícil obtención, y a que sea lo suficientemente sencillo como para que la inversión del modelo pueda realizarse en un tiempo razonable (Jacquemoud *et al.*, 2000).

Entre los modelos que se han planteado en las últimas dos décadas podemos hacer una primera distinción entre los que se centran en el nivel de la hoja *(leaf optical properties models)* y los que estiman la reflectividad del conjunto del dosel vegetal *(canopy reflectance models)*. Entre los primeros, uno de los que ha tenido mayor aceptación en la literatura ha sido el denominado PROSPECT (Jacquemoud, 1990), que describe la reflectividad de una hoja a partir de considerarla como un pila de *N* láminas compuestas de elementos absorbentes y dispersores. Permite simular la reflectividad y transmisividad de la hoja considerando una serie de variables de entrada, relacionadas con su estructura y propiedades físico-químicas. Concretamente, en su última versión (simplificada por Baret y Fourty, 1997), se requiere únicamente introducir la concentración de clorofila $a + b$ (μg cm^{-2}), el espesor equivalente de agua (EWT, *Equivalent Water Thickness*, en g cm^{-2}), el contenido de materia seca (g cm^{-2}), y el parámetro estructural *N*, que se refiere a la estructura interna de la hoja. Este parámetro es el más difícil de medir. Los mismos autores del modelo proponen estimarlo a partir del área específica de la hoja SLA *(Specific Leaf Area)*, calculada como el área por unidad de peso seco de la hoja, utilizando una relación empírica, como la siguiente (Jacquemoud, 1990):

$$N = \frac{0{,}9\,\text{SLA} + 0{,}025}{\text{SLA} - 0{,}1} \qquad [7.2]$$

El modelo PROSPECT puede aplicarse a todo el espectro óptico (de 0,4 a 2,5 μm), para anchos de banda muy pequeños, de tal forma que permite comparar los resultados con espectrometría de laboratorio y sensores hiperespectrales.

A partir de este modelo, Ceccato *et al.* (2001) han realizado una serie de simulaciones para estimar qué bandas son más sensibles para obtener el contenido de agua en las hojas. En primer lugar han analizado el efecto de variar los distintos parámetros de entrada (clorofila, materia seca, *N* y EWT) en la reflectividad estimada para el rango completo del espectro óptico, observando que el EWT afecta sólo al rango entre 0,9 y 2,5 μm, en definitiva al SWIR, pero no a las longitudes más cortas del IRC, ni al VIS. Sin embargo, la región del SWIR, no sólo está afectada por el EWT, sino también por otras variables (concretamente *N* y el contenido de materia seca), con lo que necesitamos otra banda para aislar el componente de agua. Puesto que *N* y materia seca también influyen en la reflectividad del IRC, los autores proponen como mejor estimador del EWT un índice sintético que incluya una banda en el SWIR y otra en el IRC. Siguiendo un índice de estrés hídrico propuesto previamente por Hunt y Rock (1989), evalúan la capacidad predictiva de un cociente entre la reflectividad medida en 1,6 μm y en 0,82 μm y el EWT, encontrando un magnífico ajuste logarítmico ($r^2 = 0{,}919$). Los autores dejan para una futura investigación el paso de las estimaciones a nivel de hoja con las que se deducirían del dosel vegetal.

Para las estimaciones de reflectividad del dosel se plantean otro tipo de modelos, que tienen en cuenta no sólo la reflectividad de la hoja, sino también la del suelo, así como la arquitectura de la planta y los ángulos de observación e iluminación. Según el punto de partida sobre el que realizan la modelización, los diversos modelos propuestos hasta el momento pueden clasificarse en cuatro grupos (Rencz y Ryerson, 1999; Zarco-Tejada *et al.*, 1999:

1. Modelos de turbidez: tratan la cobertura vegetal como un medio infinito, horizontalmente uniforme y plano. Los elementos de la vegetación se consideran distribuidos de forma aleatoria en capas paralelas, formadas por pequeñas partículas reflectoras, que absorben dependiendo de sus propiedades ópticas definidas por la reflectividad y transmisividad (Verhoef, 1984). Estos modelos son los más extendidos, y se ha comprobado que funcionan bien para coberturas agrícolas (Jacquemoud, 1993; Jacquemoud *et al.*, 2000; Weiss *et al.*, 2001), pero no en el caso de cubiertas forestales, en donde resultan muy importantes los aportes del suelo y del sombreado de las copas, por lo que se recomienda ampliarlos utilizando modelos geométricos (Huemmrich, 2001). También se ha propuesto emplear modelos de dos capas para simular independientemente la respuesta del dosel forestal y de la vegetación por debajo de él (Kuusk, 2001).

2. Modelos geométricos, utilizados principalmente cuando las coberturas vegetales no son densas. La cobertura es estimada a partir de un ensamblaje de formas con dimensiones y propiedades ópticas simuladas (Li y Strahler, 1986). En los últimos años, los avances en la simulación por ordenador permiten plantear modelos tri-dimensionales de reflectividad, que consiguen acercamientos bastante realistas a las condiciones de una cubierta forestal compleja (Zarco-Tejada *et al.*, 1999).

3. Modelos híbridos, son una combinación de los dos anteriores, de turbidez y geométricos, y son utilizados en aquellos casos cuando la cobertura vegetal no se adecua a ninguno de los casos anteriores. La modelización sigue siendo geométrica, pero la interacción del flujo con los elementos de la cobertura es realizada mediante modelos de turbidez. Estos modelos son los más complejos de diseñar y de cálculo más tedioso.

4. Modelos estocásticos, permiten la simulación de las posiciones y orientaciones de los elementos que forman la cobertura vegetal. Suele utilizarse el método de Monte Carlo para seguir la trayectoria del fotón desde que llega a la cobertura e interacciona con los distintos elementos vegetativos que la componen. La trayectoria es seguida hasta que, de forma aleatoria, el fotón es absorbido (por lo tanto se pierde en la cobertura) o es reflejado (y por lo tanto captado por el sensor aerotransportado o espacial).

Entre estas distintas opciones de modelar la reflectividad del dosel, los más empleados son los modelos de turbidez, gracias a su relativa simplicidad (lo que facilita su inversión para estimar variables de interés: Jacquemoud *et al.*, 2000) y buen funcionamiento en coberturas homogéneas (principalmente cultivos). Posiblemente el más empleado hasta el momento haya sido el denominado SAIL *(Scattering from Arbitrarily Inclined Leaves)* propuesto por Verhoef (1984). El SAIL requiere como parámetros de entrada la reflectividad y transmisividad de la hoja, la reflectividad del suelo, la radiancia atmosférica, el área foliar (LAI), el ángulo cenital y acimutal solar y la distribución de los ángulos de inclinación de las hojas (LAD, *Leaf Angle Distribution*) respecto a la radiación incidente. Facilita la estimación de la reflectividad del dosel para un rango completo de ángulos de observación, proporcionando en consecuencia un buen análisis de la BRDF. Además de permitir analizar la sensibilidad de las distintas variables de entrada en la reflectividad estimada, y de obtener algunos de estos parámetros por inversión del modelo, el SAIL tiene también un gran interés docente, de cara a familiarizar al estudiante con la importancia de las distintas variables de entrada en la reflectividad que mide el sensor. En este sentido, existen dos versiones de SAIL de libre acceso realizadas con fines didácticos (Barnsley y Hobson, 1997; Danson, 1998). La figura 7.5 recoge un ejemplo de la modelización que facilita uno de estos programas (Barnsley y Hobson, 1997), obteniéndose los gráficos y valores de reflectividad para cuatro bandas con distintos ángulos de observación. Todos los parámetros de entrada son modificables, de tal manera que puede observarse el efecto que tienen en el cálculo de la reflectividad del dosel.

Los modelos de dosel y de hoja pueden enlazarse con cierta facilidad, ya que la simulación a nivel de hoja puede servir de entrada para la que realicemos a nivel de dosel. Por ejemplo, el modelo PROSPECT y SAIL pueden enlazarse dinámicamente, de tal forma que se analice el efecto de modificar los parámetros de hoja o dosel en la reflectividad resultante. La figura 7.6 muestra un ejemplo de esta simulación dinámica, empleando una versión didáctica de estos programas disponible en Internet (http://www.geogra.uah.es/rtm/).

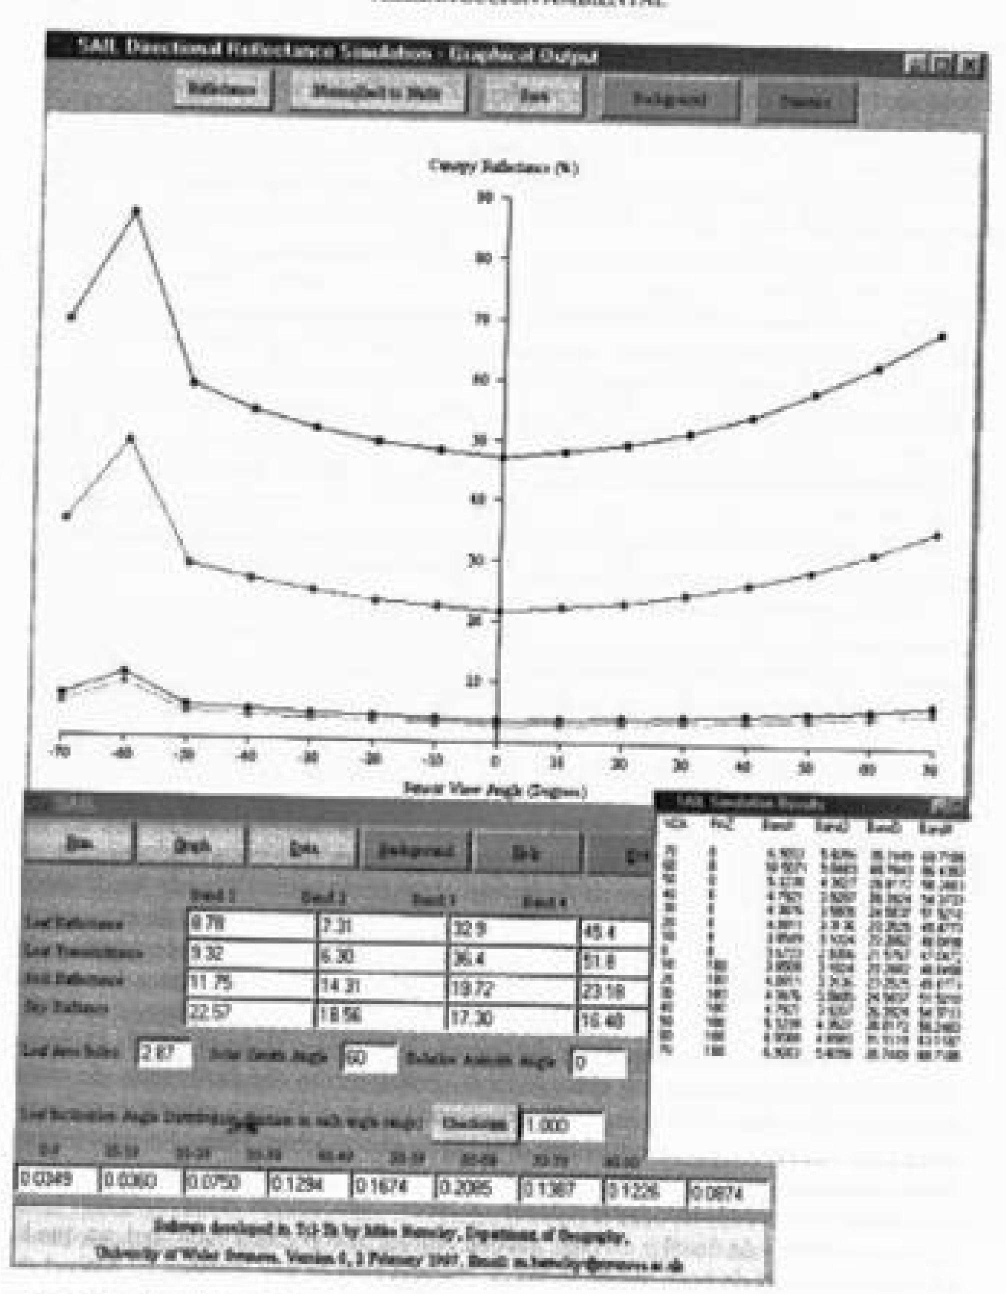


FIG. 7.5. *Resultados de la simulación con SAIL para cuatro bandas. Los datos de entrada figuran en la parte inferior. El programa corresponde a una versión de SAIL realizada por Barnsley y Hobson (1997) y está disponible en http://stress.swan.ac.uk/@mbarnsle/research/sail.htm*

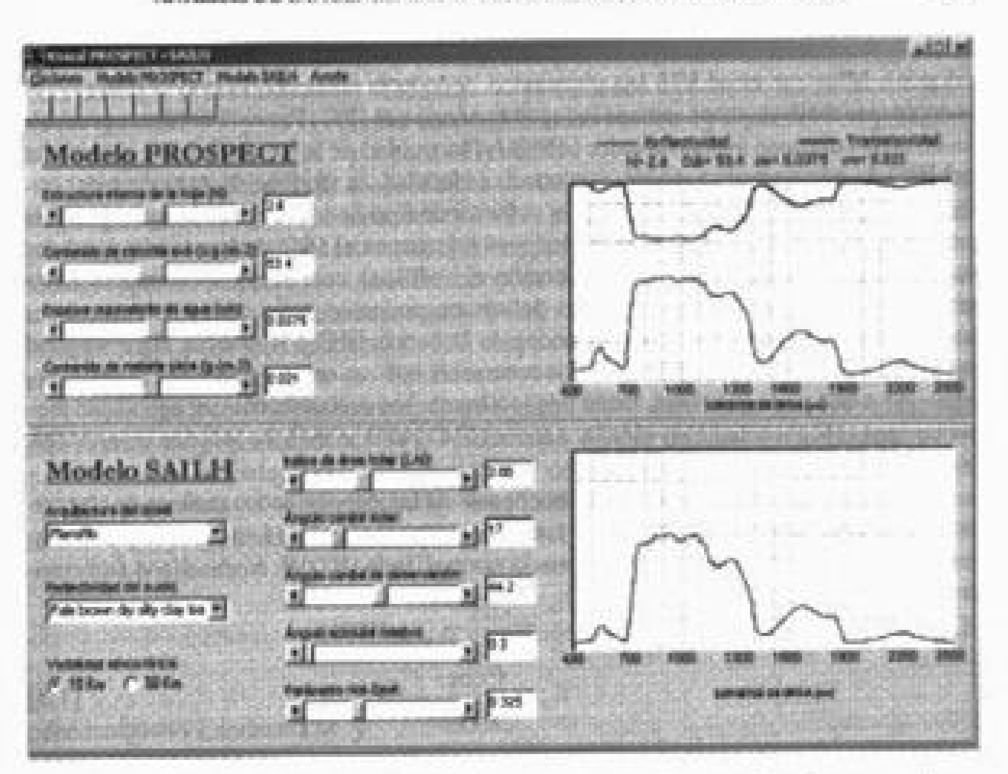


FIG. 7.6. *Simulación dinámica de la reflectividad de hoja y dosel empleando una versión didáctica de los modelos PROSPECT y SAIL. El programa fue realizado por Elena Prado, como parte de su proyecto fin de carrera y está disponible en http://www.geogra.uah.es/rtm/.*

1.2. COCIENTES E ÍNDICES DE VEGETACIÓN

Como su nombre indica, un cociente o ratio implica efectuar una división, píxel a píxel, entre los ND almacenados en dos o más bandas de la misma imagen. Se utilizan ampliamente en dos situaciones: 1) para mejorar la discriminación entre dos cubiertas con comportamiento reflectivo muy distinto en esas dos bandas, por ejemplo para realzar suelos y vegetación en el visible e infrarrojo cercano, y 2) para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral de distintas cubiertas. Como hemos visto, este objetivo no se satisface plenamente, pues los cocientes sólo eliminan parcialmente el efecto del relieve, al no considerar que los efectos atmosféricos son también dependientes de la longitud de onda. En consecuencia, para esta finalidad resulta más recomendable aplicar correcciones del sombreado topográfico, centrando el interés de estos índices en mejorar la discriminación de las cubiertas vegetales y estimar algunas de sus variables biofísicas.

El empleo de los cocientes para discriminar masas vegetales se deriva del peculiar comportamiento radiométrico de la vegetación. Como ya vimos en el capítulo 2, la signatura espectral característica de la vegetación sana muestra un claro contraste en-

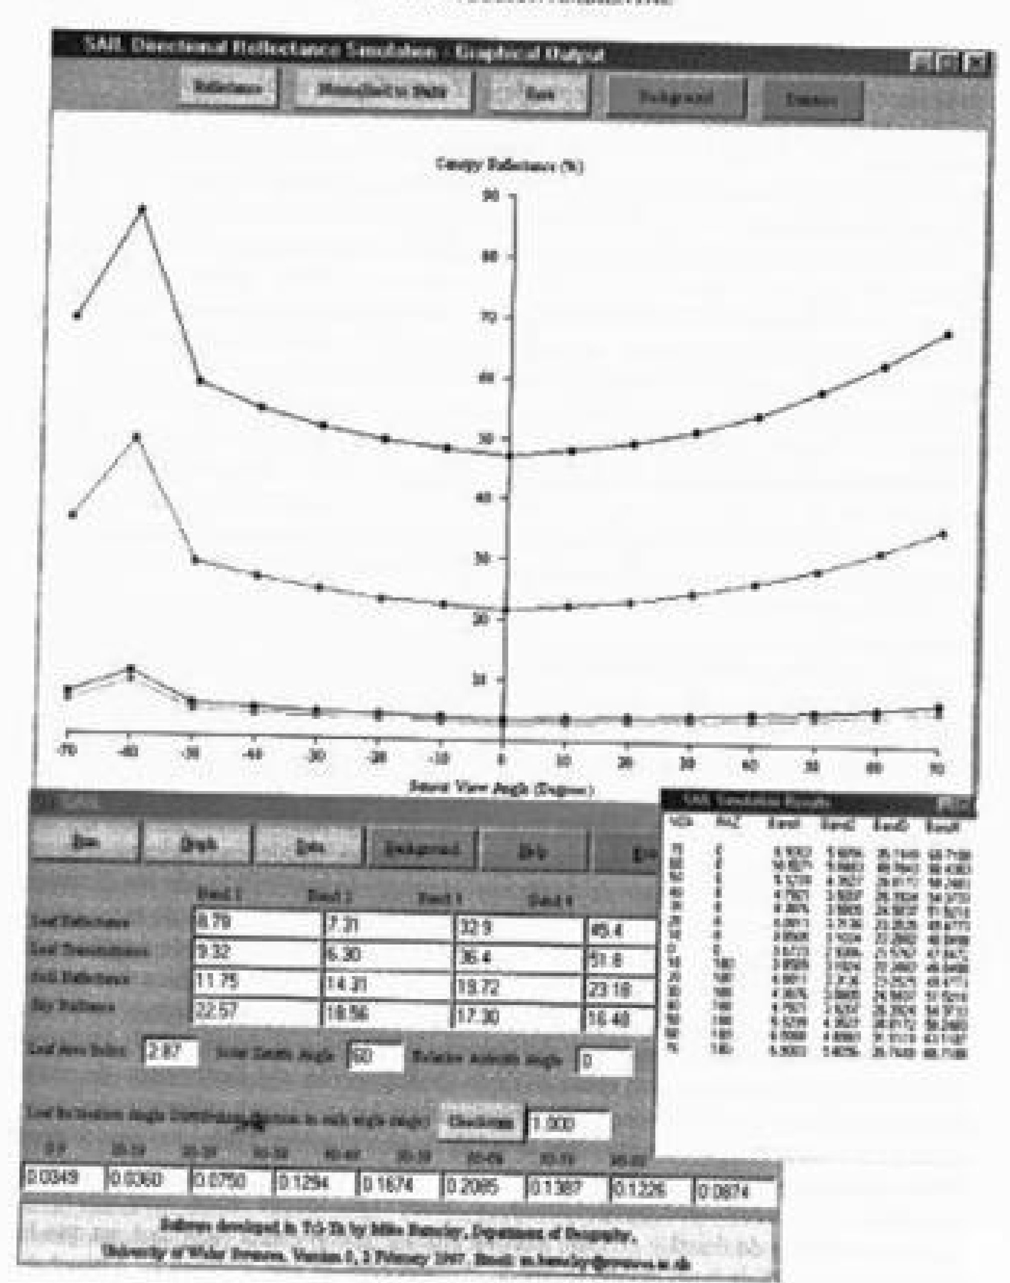


FIG. 7.5. *Resultados de la simulación con SAIL para cuatro bandas. Los datos de entrada figuran en la parte inferior. El programa corresponde a una versión de SAIL realizada por Barnsley y Hobson (1997) y está disponible en: http://stress.swan.ac.uk/~mbarnsle/research/sail.htm*

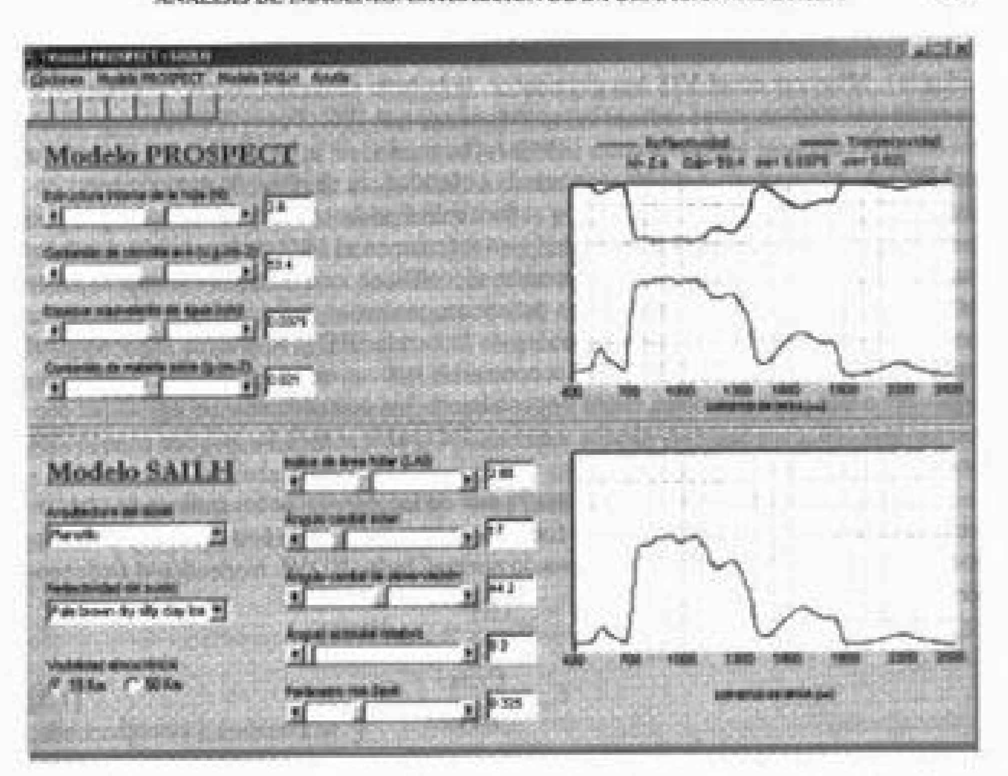


FIG. 7.6. *Simulación dinámica de la reflectividad de hoja y dosel empleando una versión didáctica de los modelos PROSPECT y SAIL. El programa fue realizado por Elena Prado, como parte de su proyecto fin de carrera y está disponible en http://www.geogra.uah.es/rtm/.*

1.2. Cocientes e índices de vegetación

Como su nombre indica, un cociente o ratio implica efectuar una división, píxel a píxel, entre los ND almacenados en dos o más bandas de la misma imagen. Se utilizan ampliamente en dos situaciones: 1) para mejorar la discriminación entre dos cubiertas con comportamiento reflectivo muy distinto en esas dos bandas, por ejemplo para realzar suelos y vegetación en el visible e infrarrojo cercano, y 2) para reducir el efecto del relieve (pendiente y orientación) en la caracterización espectral de distintas cubiertas. Como hemos visto, este objetivo no se satisface plenamente, pues los cocientes sólo eliminan parcialmente el efecto del relieve, al no considerar que los efectos atmosféricos son también dependientes de la longitud de onda. En consecuencia, para esta finalidad resulta más recomendable aplicar correcciones del sombreado topográfico, centrando el interés de estos índices en mejorar la discriminación de las cubiertas vegetales y estimar algunas de sus variables biofísicas.

El empleo de los cocientes para discriminar masas vegetales se deriva del peculiar comportamiento radiométrico de la vegetación. Como ya vimos en el capítulo 2, la signatura espectral característica de la vegetación sana muestra un claro contraste en-

tre las bandas del VIS —y especialmente la banda roja (0,6 a 0,7 μm)— y el IRC (0,7 a 1,1 μm). Mientras en el VIS los pigmentos de la hoja absorben la mayor parte de la energía que reciben, estas sustancias apenas afectan al IRC. Por esta razón se produce un notable contraste espectral entre la baja reflectividad de la banda R del espectro y la del IRC, lo que permite separar, con relativa claridad, la vegetación sana de otras cubiertas (fig. 7.7). Cuando la vegetación sufre algún tipo de estrés (por ejemplo, por plagas o sequías intensas), su reflectividad será inferior en el IRC, aumentando paralelamente en el rojo (al tener menor absorción clorofílica), con lo que el contraste entre ambas bandas será mucho menor. En definitiva, podemos señalar que cuanto mayor sea la diferencia entre las reflectividades de la banda IRC y R, mayor vigor vegetal presentará la cubierta observada. Bajos contrastes indican una vegetación enferma, senescente o con poca densidad, hasta llegar a los suelos descubiertos o el agua, que presentan una reflectividad muy similar entre el IRC y el R, o incluso inferior en esta última (caso del agua o algunas nubes).

En este principio se apoyan la mayor parte de los denominados índices de vegetación (IV). Los más empleados son el cociente simple entre esas bandas (C), y el denominado índice de vegetación de diferencia normalizada (NDVI, *Normalized Difference Vegetation Index*):

$$C_i = \frac{\rho_{i,IRC}}{\rho_{i,R}} \qquad [7.3]$$

y

$$NDVI_i = \frac{\rho_{i,IRC} - \rho_{i,R}}{\rho_{i,IRC} + \rho_{i,R}} \qquad [7.4]$$

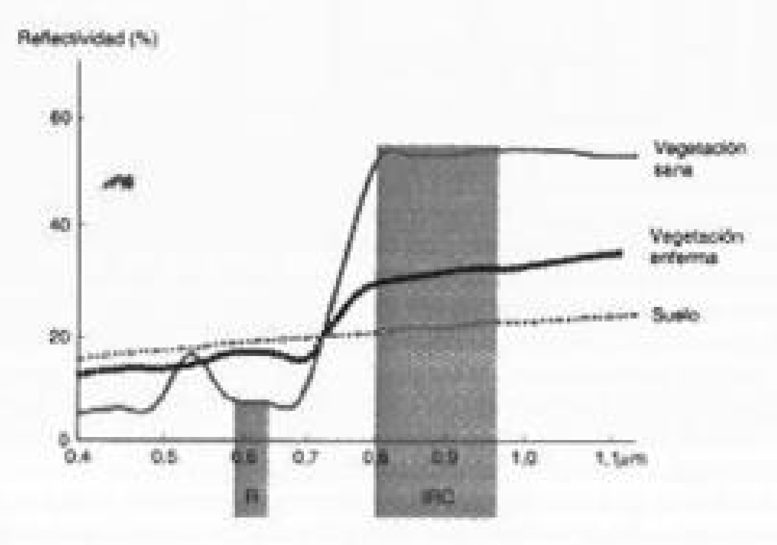


FIG. 7.7. *Contraste espectral de la vegetación sana entre las bandas R e IRC del espectro.*

donde $\rho_{i,IRC}$ y $\rho_{i,R}$ indican las reflectividades del píxel i en la banda del infrarrojo cercano y del rojo, respectivamente. Esos índices se obtienen a partir de las reflectividades de las bandas 7 y 5, para el caso del sensor MSS; las bandas 4 y 3 para el TM y ETM+; la 3 y 2, para el HRV, y la 2 y 1 para el AVHRR.

Si bien la definición de estos índices se realiza a partir de reflectividades (lo que implica abordar las correcciones atmosféricas y topográficas vistas previamente), algunos autores no tienen inconveniente en emplear directamente los ND de la imagen, siempre que no se pretenda conceder un valor físico a los resultados. En ese caso, el cociente o índice de vegetación presentará una valoración relativa, aunque sigue manteniéndose el principio anterior: cuanto mayor sea el resultado, mayor vigor vegetal presenta la zona observada.

Aplicando un modelo teórico, Guyot y Gu (1994) concluyen que los valores del NDVI para imágenes Landsat y SPOT calculados a partir de ND subestiman entre 0,05 y 0,20 el valor calculado con reflectividades, siendo este error mayor con valores de NDVI inferiores a 0,5 y para las imágenes SPOT. En consecuencia, proponen una corrección que haga equivalente el cálculo con ND o reflectividades:

$$NDVI_{TM,\rho} = \frac{ND_{IRC} - 0{,}801\, ND_R}{ND_{IRC} + 0{,}801\, ND_R} \qquad [7.5]$$

para imágenes Landsat-TM, y

$$NDVI_{HRV,\rho} = \frac{ND_{IRC} - 0{,}663\, ND_R}{ND_{IRC} + 0{,}663\, ND_R} \qquad [7.6]$$

para imágenes SPOT-HRV.

Un aspecto de gran interés del NDVI, frente al cociente simple, es que varía entre unos márgenes conocidos, entre −1 y +1, lo que facilita notablemente su interpretación. Por ejemplo, podemos señalar como umbral crítico para cubiertas vegetales un valor de NDVI en torno a 0.1 y para la vegetación densa entre 0,5 y 0,7 (Holben, 1986).

Tanto el NDVI como el cociente simple se han empleado profusamente para estimar diversos parámetros de la cubierta vegetal, lo que les confiere un papel protagonista de cara a la evaluación ambiental, especialmente con un enfoque global. Entre los parámetros que se han relacionado satisfactoriamente con el NDVI están los siguientes:

1. Contenido de clorofila en la hoja, es la variable más directamente relacionada con este índice, ya que la absorción de la banda R está nítidamente influida por este parámetro. En consecuencia, el NDVI presenta correlaciones altas y linealmente positivas con la cantidad de clorofila en la hoja (Curran, 1989; Wesman, 1994; Zarco-Tejada *et al.*, 2001).
2. Contenido de agua en la hoja, a través de correlaciones negativas y lineales, según algunos autores (Hardy y Burgan, 1999; Westman y Price, 1988), aunque para

otros, en realidad esta estimación sólo se hace de modo indirecto, a través del efecto del estrés hídrico sobre el LAI y el contenido de clorofila (Ceccato *et al.*, 2001; Chuvieco *et al.*, 1999*b*; Hunt y Rock, 1989).

3. Flujo neto de CO_2, tanto a nivel local (Hall *et al.*, 1991*b*), como global (Tucker *et al.*, 1986).

4. Radiación fotosintéticamente activa absorbida por la planta, APAR, con una relación directa y casi lineal (Asrar *et al.*, 1989), especialmente cuando las hojas son horizontales y el suelo es suficientemente oscuro (Sellers, 1989).

5. Productividad neta de la vegetación, relacionada con la APAR a través de un factor de eficiencia para cada planta (Steven y Jaggard, 1995). De modo indirecto, puede estimarse a partir del NDVI la biomasa verde y seca, aunque aquí los grados de ajuste varían mucho con los estudios, desde los muy buenos (Holben, 1980; Kennedy, 1989) hasta los bastante discretos (Tucker, 1979).

6. Índice de área foliar, LAI, que presenta una asociación positiva con el NDVI, especialmente cuando la vegetación no cubre totalmente el suelo, ya que a ciertos valores de LAI (por encima de 4, habitualmente), el NDVI se satura (Baret, 1995; Sellers, 1989). En consecuencia, más bien hemos de considerar que se trata de una relación asintótica (Sellers, 1987). Relacionado con este índice se ha comprobado una alta correlación entre NDVI y porcentaje de cubierta verde (Kennedy *et al.*, 1994; Kerr *et al.*, 1992).

7. Cantidad de lluvia recibida por el dosel vegetal, lo que está directamente relacionado con su vigor vegetal, aunque habitualmente se presente un cierto desfase entre la precipitación y la respuesta de la cubierta vegetal (Millington *et al.*, 1994; Potter y Brooks, 2000; Taylor *et al.*, 1985)

8. Dinámica fenológica, a partir de seguir la evolución estacional de los parámetros antes señalados (Sampson, 1993; Potter y Brooks, 2000).

9. Evapotranspiración potencial, inversamente relacionada con los índices de vegetación a través del vigor de la hoja y el estrés hídrico (Cihlar *et al.*, 1991; Sánchez y Chuvieco, 2000).

Obviamente, si los índices de vegetación se relacionan bien con estas variables es porque ellas mismas están relacionadas entre sí (Verstraete y Pinty, 1996), a través de los mecanismos vitales de las plantas. El problema que se plantea en la interpretación cuantitativa de estos índices es la validez global de las funciones encontradas, ya que la mayor parte de los estudios citados previamente se basan en ajustes empíricos. El reto de los próximos años será plantear relaciones más generalizables, basadas tal vez en modelos físicos, que permitan extraer, a partir de estos índices, las variables de interés de modo más preciso y consistente.

Mientras se avanza en esa dirección, el NDVI —gracias a su facilidad de cálculo y fácil interpretación— se están empleando de modo rutinario en el seguimiento y evaluación de la dinámica global de la vegetación terrestre. Desde hace más de una década el programa internacional para el estudio de la geosfera y la biosfera (IGBP), junto a otros recursos nacionales, promueve la realización de mosaicos mundiales y diarios de NDVI a partir de imágenes NOAA. Estos datos se utilizan para seguir el efecto del cambio estacional en el vigor de las cubiertas vegetales, el efecto de procesos globales continuos, como puede ser el calentamiento terrestre, o de fenómenos esporádicos,

como pueden ser los provocados por El Niño (Curran y Foody, 1994*a*; Gutman, 1994). Las series multitemporales de IV se están empleado satisfactoriamente en el análisis de la desertización (Becker y Choudhury, 1988; Chen *et al.*, 1998; Tucker *et al.*, 1994), la deforestación tropical (Malingreau *et al.*, 1989; Nelson, 1994), la prevención de incendios forestales (Burgan *et al.*, 1998; Chuvieco *et al.*, 1999*b*; Illera *et al.*, 1996; Paltridge y Barber, 1988), la cartografía de áreas quemadas (Fernández *et al.*, 1997; Fraser *et al.*, 2000; Martín y Chuvieco, 1998; Pereira *et al.*, 1999) y la cartografía global de la cobertura del suelo (Loveland *et al.*, 1991; Millington *et al.*, 1994; Tateishi y Kajiwara, 1991; Tucker *et al.*, 1985).

Varios autores han puesto de relieve el efecto de factores externos en el valor del NDVI, por lo que se han propuesto numerosas alternativas que intentan paliar algunos de estos problemas. De esta forma, la lista de IV disponibles es muy amplia (Bannari *et al.*, 1995), si bien la mayor parte presentan valores de correlación muy altos (Perry y Lautenschlager, 1984). No obstante, por su posible interés en distintas aplicaciones ambientales, revisaremos algunos de estos índices.

Entre los factores que modifican notablemente el comportamiento del NDVI figura la proporción de vegetación/suelo observada por el sensor. Los mismos valores de NDVI pueden corresponder a cubiertas vigorosas pero poco densas, o a cubiertas densas con poca vitalidad. Para incluir explícitamente el factor suelo, clave cuando se trabaja en zonas áridas, Huete y colaboradores propusieron incluir en la fórmula del NDVI un parámetro (*L*), que ajuste el índice a una reflectividad promedio de fondo (Huete, 1988; Huete *et al.*, 1992). De esta forma se calcula el índice de vegetación ajustado al suelo (SAVI):

$$\mathrm{SAVI}_{i,j} = \frac{\rho_{i,j,\mathrm{IRC}} - \rho_{i,j,\mathrm{R}}}{\rho_{i,j,\mathrm{IRC}} + \rho_{i,j,\mathrm{R}} + L}(1 + L) \qquad [7.7]$$

donde *L* indica una constante para ajustar la línea vegetación-suelo al origen (los autores indican un posible valor en torno a 0,5: Huete *et al.*, 1994). En estudios experimentales sobre campos de hierba y algodón se comprobó que este índice reducía sustancialmente las variaciones inducidas por el suelo en comparación con el NDVI y otros índices, en la mayoría de las condiciones de la vegetación (Huete, 1987).

Otro factor de importancia en el cálculo del NDVI es el efecto de absorción atmosférica, que tiende en principio a reducir el valor del índice (Cachorro *et al.*, 2000; Myneni y Asrar, 1994). Estos efectos se acentúan para los píxeles extremos en caso de observación oblicua, como ocurre en las imágenes del AVHRR o de otros sensores de ámbito global. Con imágenes AVHRR, este problema tiende a solventarse mediante técnicas de composición multitemporal, que intentan elegir en una serie de imágenes diarias el valor del píxel más cercano a una adquisición ideal (con atmósfera transparente y cerca del nadir), al coste de perder la resolución diaria (normalmente los compuestos se forman para períodos de entre 7 y 15 días). Esto garantiza que el NDVI seleccionado esté menos influido por ruidos externos a la cubierta observada. Entre las técnicas de composición más comunes se encuentra el máximo valor compuesto (Holben, 1986), que elige el valor mayor de NDVI de la serie diaria que se considere, si bien se han propuesto otras técnicas para intentar salvaguardar mejor la resolución

temporal de las imágenes (Cihlar *et al.*, 1994; Moody y Strahler, 1994; Viovy *et al.*, 1992).

Como es lógico, esta solución para los problemas atmosféricos de los IV no resulta razonable para las imágenes de mayor resolución espacial (y menor temporal), ya que supondrían una inversión muy alta y perderíamos demasiada información temporal. Una alternativa sería ajustar el NDVI a las condiciones atmosféricas, teniendo en cuenta la diferente dispersión de los canales azul y rojo del espectro. De esta forma se define el denominado índice de vegetación atmosféricamente resistente (ARVI: Kaufman y Tanré, 1992):

$$\text{ARVI}_i = \frac{\rho^*_{IRC} - \rho^*_{RA}}{\rho^*_{IRC} + \rho^*_{RA}} \qquad [7.8]$$

donde ρ^*_{IRC} indica la reflectividad aparente en el infrarrojo cercano y ρ^*_{RA} un factor que considera la diferencia de reflectividad entre el azul y el rojo, y se define como:

$$\rho^*_{RA} = \rho^*_R - \gamma(\rho^*_A - \rho^*_R) \qquad [7.9]$$

donde ρ^*_A y ρ^*_R indican las reflectividades aparentes en el azul y rojo, respectivamente, y γ es un parámetro de calibración, que depende del tipo de atmósfera, aunque para la mayor parte de los casos es igual a 1.

Otro índice propuesto para reducir simultáneamente el efecto atmosférico y de cambios en el color del suelo es el denominado GEMI (*Global Environment Monitoring Index*), definido para imágenes AVHRR como (Pinty y Verstraete, 1992):

$$\text{GEMI} = \eta \times (1 - 0{,}25 \times \eta) - \frac{\rho_R - 0{,}125}{1 - \rho_R} \qquad [7.10]$$

donde

$$\eta = \frac{2 \times (\rho^2_{IRC} - \rho^2_R) + 1{,}5 \times \rho_{IRC} + 0{,}5_R \times \rho_R}{\rho_{IRC} + \rho_R + 0{,}5} \qquad [7.11]$$

No obstante el interés de estos índices, siempre resulta más recomendable utilizar una previa corrección atmosférica de las bandas R e IRC. De esta manera los efectos atmosféricos sobre el índice pueden minimizarse considerablemente.

La figura 7.8 presenta el NDVI calculado para la imagen Torrel00. Se observan con nitidez las cubiertas de vegetación más vigorosa, como los pastizales próximos a Colmenar y Soto del Real. Los embalses ofrecen los valores más bajos de NDVI (A en la figura), así como las zonas urbanas de densa edificación (véase el casco urbano de Soto, B, o de Colmenar, C). Por su parte, las áreas de urbanización ajardinada presentan unos valores de NDVI más altos (D), sobre un entramado regular más oscuro (viales).



FIG. 7.8. *Fragmento de la imagen Torrel00 mostrando el NDVI para láminas de agua (A), zonas urbanas (B, C) y áreas residenciales (D).*

Todos los índices hasta aquí comentados se dirigen a realzar las cubiertas vegetales frente a otras superficies, a través del contraste que presenta la reflectividad de las plantas entre el IRC y el *R*. Ahora bien, en caso de que nos interese analizar otras variables en la vegetación, u otro tipo de cubiertas no vegetales, estas bandas pueden no ser las más idóneas. En esos casos convendrá acudir a un análisis de las variaciones espectrales que introduce la variable de interés para proponer índices alternativos a los que hemos visto hasta el momento. Por ejemplo, si lo que se pretende es realzar la discriminación de las áreas forestales quemadas frente a otras cubiertas no afectadas por el fuego, los IV presentados no resultan una buena alternativa, ya que no están diseñados para los rangos espectrales correspondientes a la vegetación quemada. En consecuencia, ofrecen rasgos de discriminabilidad peores que otros índices diseñados específicamente para esta finalidad (Chuvieco y Martín, 1999; Martín, 1998; Pereira, 1999; Trigg y Flasse, 2001).

De igual manera, cuando se pretenda analizar el contenido de agua en la vegetación, como ya hemos visto previamente, el espacio espectral más idóneo no está formado por las bandas IRC-R, sino más bien por las SWIR-IRC, ya que la absorción del agua se produce en el SWIR y no en el visible. Por tanto, al aumentar el contenido de agua en el suelo o la vegetación disminuye paralelamente la reflectividad en el SWIR. Por su parte, el IRC informa sobre el grado de deterioro de la hoja a partir de su correlación negativa con el apelmazamiento que pueden producir distintas fuentes de

estrés (como por ejemplo, el hídrico). Sobre esta base se han definido los denominados índices de contenido de agua, estrés hídrico o sequía (según los autores) que remarcan el contraste entre IRC y SWIR. Entre los propuestos cabe citar el NDII *(Normalized Difference Infrared Index)*, definido como (Hunt y Rock, 1989):

$$NDII = \frac{\rho_{IRC} - \rho_{SWIR}}{\rho_{IRC} + \rho_{SWIR}} \qquad [7.12]$$

donde ρ_{IRC} y ρ_{SWIR} son las reflectividades del IRC y SWIR, respectivamente. Se ha comprobado en varios estudios que este tipo de índices son más adecuados que el NDVI para estimar contenido de agua en vegetación (Aldakheel y Danson, 1997; Ceccato *et al.*, 2001; Chuvieco *et al.*, 2002*b*; Cibula *et al.*, 1992; Cohen, 1991; Gao, 1996; Riaño *et al.*, 2000; Ustin *et al.*, 1998).

También se ha comprobado que estos índices IRC-SWIR resultan más eficaces para cartografiar áreas quemadas que los basados en el IRC-R, puesto que la señal quemada es más nítida en el SWIR y hay menos alteraciones de otros factores externos, como la atmósfera (Pereira, 1999; Pereira *et al.*, 1997).

Finalmente se han propuesto otros cocientes de bandas para enfatizar cubiertas no vegetales, especialmente en trabajos de exploración minera. Este tipo de estudios sólo parecen viables en áreas de vegetación escasa, con objeto de obviar el efecto pantalla de la cubierta vegetal. En un trabajo realizado a partir de imágenes TM sobre el desierto del Mohave (California), se mostró el interés de los siguientes cocientes: TM5/TM7, para detectar rocas alteradas hidro-térmicamente, con alto contenido de arcillas, micas y rocas sulfatadas; TM5/TM4, para aislar las cubiertas vegetales del roquedo desnudo, y TM3/TM1, para aquellos materiales con importante presencia de limonita (Kruse *et al.*, 1993*a*; Podwysocki *et al.*, 1985).

1.3. Componentes principales

El Análisis de Componentes Principales (ACP) es una técnica bastante empleada en ciencias sociales y naturales. Su objetivo es resumir la información contenida en un grupo amplio de variables en un nuevo conjunto, más pequeño, sin perder una parte significativa de esa información.

El origen de esta técnica parece arrancar del campo de la sicometría: al analizar una serie de tests de inteligencia, se intuía la presencia de una serie de factores, subyacentes a las variables medidas, que podrían explicar gran parte de la variación común en determinados grupos de variables. Por ejemplo, se comprobó que las puntuaciones obtenidas por los alumnos de física y matemáticas tendían a estar bastante relacionadas, así como las obtenidas por otros en historia y literatura. Esto hacía pensar en la existencia de otras variables más complejas, como la habilidad para el cálculo o la capacidad de abstracción, que permitirían resumir la información contenida en las variables originales. Esas nuevas variables, los componentes o factores principales, podrían derivarse a partir de las variables originales, estudiando sus relaciones comunes tal y como se miden en la matriz de varianza-covarianza. Los factores o componentes principales vendrían, por tanto, a ser como variables-resumen de las medidas inicialmente: un menor número de dimensiones, preservando lo más sustancioso de la información original.

Esta capacidad de síntesis ha sido la base de la aplicación del ACP en teledetección. La adquisición de imágenes sobre bandas adyacentes del espectro, implica con frecuencia detectar una información redundante, puesto que los tipos de cubierta tienden a presentar un comportamiento similar en longitudes de onda próximas. Por ello, las medidas realizadas en una banda pueden presentar una importante correlación con las deducidas de otra, haciendo una o varias de ellas prácticamente irrelevantes. En este contexto, el ACP permite sintetizar las bandas originales, creando unas nuevas bandas —los componentes principales de la imagen—, que recojan la parte más relevante de la información original. Esta síntesis resulta muy conveniente cuando se pretende abordar un análisis multitemporal (Joly *et al.*, 1983; Maselli *et al.*, 1995), o cuando se intentan seleccionar las tres bandas más adecuadas para una composición en color (Chavez y Kwarteng, 1989; Green *et al.*, 1988). También se han utilizado bastante en la exploración geológica (Hervás, 1987). La selección de bandas no correlacionadas, o con mayor contenido de información, resulta especialmente crítica en el entorno del análisis hiperespectral (1.6), ya que al tener disponibles una gran cantidad de bandas, resulta complejo extraer la estructura dominante de la imagen (Palacios-Orueta y Ustin, 1996; Palacios-Orueta *et al.*, 1999; Ustin y Trabucco, 2000).

Por otra parte, y desde el punto de vista meramente estadístico, el ACP facilita una primera interpretación sobre los ejes de variabilidad de la imagen, lo que permite identificar aquellos rasgos que se recogen en la mayor parte de las bandas y aquellos otros que son específicos a algún grupo de ellas (Palacios-Orueta y Ustin, 1996). En definitiva, proporciona una mejor distribución de los datos, frente a esos ejes de variabilidad, lo que puede facilitar una identificación más atinada de las distintas cubiertas.

Como es bien sabido, el sentido y la fuerza de la correlación lineal entre dos variables puede representarse gráficamente mediante un eje bivariado. En nuestro contexto, la nube de puntos indica la localización de los ND en las dos bandas consideradas. La elipse que limita estos puntos, expresa gráficamente la fuerza de la correlación entre las dos bandas, tanto mayor cuanto más se aproxime a una recta, o —dicho de otro modo— cuanto mayor sea el contraste entre los dos ejes de esa elipse. En la figura 7.9 aparece una correlación positiva elevada con dos ejes de variación: el primero en el sentido de la correlación (*A*), y el segundo en el sentido de los residuales (*B*). Conviene considerar que este segundo componente es ortogonal al primero, lo que indica, en términos estadísticos, que los componentes principales no están correlacionados; esto es, que la información que contienen es específica.

Gráficamente se intuye que una rotación de los ejes *X*, *Y* hacia las direcciones *A*, *B*, mejorará la disposición original de los datos, y probablemente también la separación entre los grupos de ND homogéneos en la imagen. Esa rotación se obtiene, simplemente, aplicando una función del tipo:

$$CP_1 = a_{11} ND_1 + a_{12} ND_2 \qquad [7.13]$$

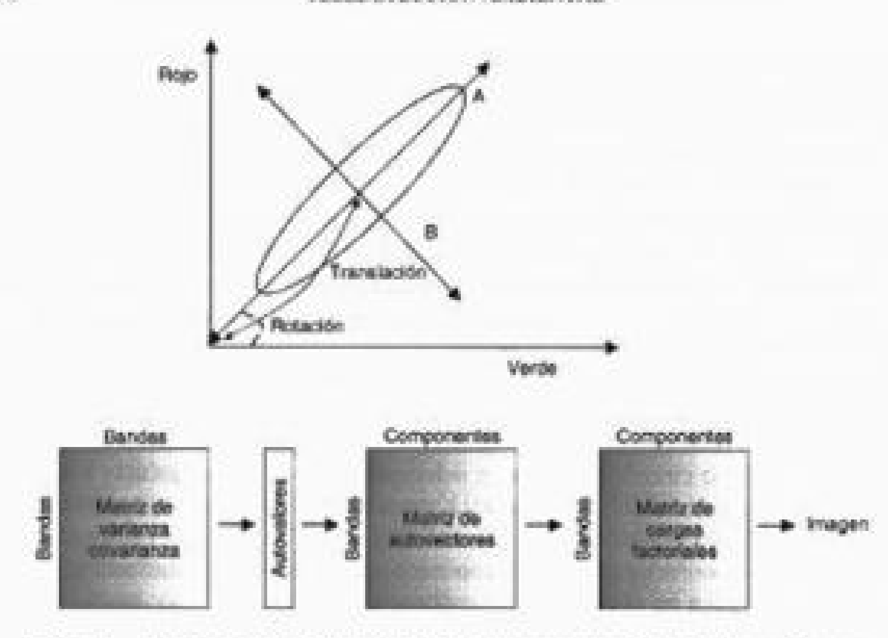


FIG. 7.9. *Proceso para la obtención de los componentes principales de una imagen.*

donde CP_1 indica el valor correspondiente al primer componente principal, obtenido a partir de los ND originales de las bandas *i* y *k*, tras aplicarles unos determinados coeficientes a_{11} y a_{12}. Desde el punto de vista geométrico, y como puede observarse en la figura 7.9, este nuevo eje sólo supone una rotación de los originales. En ocasiones puede ser de gran interés acompañar la rotación con una traslación de los ejes, situando el origen de coordenadas en los valores mínimos de las dos bandas implicadas en el proceso. Basta, para ello, añadir dos constantes a_{01} y a_{02} a la ecuación arriba señalada.

En términos más generales, los componentes principales de una imagen se obtienen de acuerdo a:

$$CP_j = \Sigma_{i=1,p}\, a_{i,j}\, ND_i + R_j \qquad [7.14]$$

donde CP_j indica el ND correspondiente al componente principal *j*, $a_{i,j}$ el coeficiente aplicado al ND de la banda *i* para generar el componente *j* y R_j una constante que suele introducirse en cada componente para evitar valores negativos. Otra posibilidad es escalar los valores resultantes, por ejemplo a 0-255, evitando la constante. Como hemos indicado, hay tantos componentes (*p*) como bandas, pero la forma de extraer esos componentes implica que sólo los primeros tienen una información significativa.

La obtención de los *CP* de una imagen implica una transformación matemática compleja, que no parece oportuno detallar aquí.[2] En términos sencillos, el proceso puede resumirse en los siguientes pasos. A partir de la matriz de varianza-covarianza de las bandas que componen la imagen original se extraen los autovalores (ξ_j) que expresan la longitud de cada uno de los nuevos componentes, y, en última instancia, la proporción de información original que retienen. Este dato resulta de gran interés para decidir qué componentes principales son más interesantes; habitualmente los que mayor información original retengan. Tal y como se obtienen los *CP*, el autovalor va disminuyendo progresivamente, del primero a los últimos, pues se pretende maximizar sucesivamente la varianza extraída en el análisis. La varianza original explicada por cada componente se calcula como la proporción de su autovalor frente a la suma de todos los autovalores:

2. En el contexto del tratamiento digital de imágenes puede consultarse Short (1982, pp. 174 y ss.), Gonzalez y Wintz (1977), Thomas *et al.* (1987*a*) y Richards (1993).

$$V_j = \frac{\xi_j}{\sum_{j=1,p} \xi_j} \qquad [7.15]$$

siendo *p* el número total de componentes.

Junto a la longitud de cada eje, nos resulta también de gran interés conocer su dirección. En definitiva, para poder interpretar el sentido de las nuevas variables se requiere conocer su relación con las originales. De igual forma, para calcular las ecuaciones que servirán para obtener las nuevas imágenes se precisa contar con los coeficientes de la transformación. Ambos aspectos pueden abordarse a partir de los autovectores. El autovector indica la ponderación que debe aplicarse a cada una de las bandas originales para obtener el nuevo *CP* ($a_{i,j}$ en la fórmula [7.14]). Dicho brevemente, equivale a los coeficientes de regresión en una transformación lineal estándar, siendo las bandas de la imagen las variables independientes y los *CP* las dependientes.

A partir de los autovectores se calcula la matriz de correlación entre *CP* y bandas de la imagen, lo que nos permite conocer el sentido espectral de estos componentes. Basta aplicar:

$$r_{i,j} = \frac{a_{i,j}\sqrt{\xi_j}}{s_i} \qquad [7.16]$$

donde $r_{i,j}$ indica el coeficiente de correlación entre el componente *j* y la banda *i*; $a_{i,j}$ el autovector de ese componente en la misma banda; ξ_j, el autovalor del componente *j*, y s_i la desviación típica de la banda *i*.

El último paso es obtener una imagen de los componentes principales, a partir de [7.14]. Obtenida la imagen de los *CP*, pueden éstos representarse en blanco y negro o color, obteniéndose una nueva visualización de la zona de estudio. Para ello convendrá escalar los resultados en el rango más común en un equipo de visualización (0 a 255). Una forma sencilla de abordar este proceso sería realizar una pequeña muestra de los valores resultantes, con objeto de estimar los valores máximos y mínimos, aplicando luego alguno de los procedimientos para expandir el contraste que se han mencionado anteriormente.

Para ilustrar el interés del ACP en la interpretación digital de imágenes se aplicó esta técnica sobre las seis bandas no térmicas de la imagen Torrel00. A partir de una muestra sistemática de 1 de cada 8 píxeles se obtuvo la matriz de varianza-covarianza para esas bandas (tabla 7.2). Sobre esa matriz se calcularon los autovalores de la ima-

TABLA 7.2. *Matriz de varianza-covarianza de la imagen Torre100*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
B1	102,83					
B2	107,91	123,68				
B3	156,30	176,07	271,58			
B4	71,71	114,86	127,63	583,76		
B5	148,94	183,70	275,91	340,63	516,96	
B7	141,22	161,53	251,25	157,26	369,24	314,29

gen, realizando una previa estandarización, con objeto de paliar el efecto de la distinta variabilidad entre bandas. Los autovalores (ξ_i) extraídos fueron: 1.365,72, 410,24, 115,60, 9,64, 9,05 y 2,83. De acuerdo a [7.15], la varianza original asociada con cada uno de estos componentes resultó ser 71,39 % para el primer componente; 21,44 % para el segundo; 6,04 % para el tercero; 0,50 % para el cuarto; 0,47 % para el quinto, y 0,15 % para el sexto. De acuerdo a estos porcentajes se seleccionaron únicamente los tres primeros componentes, que retenían un total del 98,87 % de la varianza original de la imagen.

El sentido espectral de estos componentes se obtuvo a partir de la matriz de autovectores, en donde se evidencia la asociación entre cada componente y las bandas originales. Como puede analizarse en la tabla 7.3, el primer componente ofrece un promedio ponderado de todas las bandas. Recoge, en consecuencia, una valoración de las características espectrales comunes a todas ellas, lo que puede asimilarse con el brillo general de la imagen, similar al aspecto que podría presentar una banda pancromática. Esta interpretación es bastante generalizable para el primer componente de la mayor parte de las imágenes tomadas en el espectro solar, ya que el factor más común a la variación espectral en estas longitudes de onda es la reflectividad promedio. El segundo componente muestra una importante asociación positiva con la banda 4, apenas perceptible con la 5 y moderadamente negativa con el resto. En definitiva, está evidenciando el contraste espectral entre el IRC y el resto de las bandas consideradas (VIS y SWIR), lo que muestra una valoración del vigor vegetal de la imagen. Finalmente, el tercer componente ofrece un claro contraste entre el VIS-IRC y el SWIR, con correlaciones positivas para las primeras bandas y negativas para las segundas. Esto parece indicar una valoración del contenido de agua, por lo que le denominaremos como componente humedad.

Las imágenes de los CP resultantes parecen demostrar esta interpretación preliminar. El primero presenta una fisonomía muy similar a la de una imagen pancromática, con valores promedio de las distintas cubiertas: bajos valores en el agua y la vege-

TABLA 7.3. *Matriz de auto-vectores de la imagen Torre100*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
CP1	0,213	0,258	0,374	0,462	0,589	0,434
CP2	–0,213	0,171	–0,354	0,834	–0,041	–0,321
CP3	0,381	0,400	0,464	0,238	–0,585	–0,284

tación, medios en los espacios edificados, y altos en los suelos descubiertos (fig. 7.10*a*). El segundo componente evidencia los sectores con una actividad clorofílica más intensa, como son los pastizales y cultivos de secano (recuérdese que la imagen está tomada muy cerca de la primavera), ofreciendo tonos medios para los pinares del vértice *SW* y las diversas urbanizaciones, y tonos oscuros para los suelos descubiertos, agua y vías de comunicación (fig. 7.10*b*). Por último, el tercer componente remarca con claridad las láminas de agua, vías de comunicación y espacios edificados, que ocupan el intervalo más alto de la imagen. Ofrecen tonos medios los pinares y las áreas de caducifolias todavía sin hojas, seguramente por el efecto de sombras en el suelo. Por el contrario, la vegetación manifiesta tonos gris-medio a oscuro, en función de su vigor, mostrando los matorrales tonos intermedios y los cultivos de secano más oscuros (fig. 7.10*c*).

También puede generarse una composición en color con los tres primeros componentes principales, de cara a facilitar una interpretación más sintética de la información que incluyen. Para el caso de Torrel00 (fig. 13*) hemos asignado el cañón de color rojo al primer componente, el verde al segundo, y el azul al tercero. Las áreas de mayor vigor vegetal aparecen en verde o cian (alto verdor, bajo brillo y media humedad), mientras los suelos descubiertos o áreas urbanas aparecen en magenta (alto brillo y humedad), y las láminas de agua en azul.

La capacidad de síntesis propia del ACP la hacen una técnica muy apropiada como filtro previo para el análisis multitemporal, cuando se van a utilizar varias imágenes en una sola clasificación. En ese caso, el ACP sirve para retener la información más significativa de cada período. Posteriormente, los CP de cada fecha se combinan, con objeto de facilitar una mejor discriminación de cubiertas con perfiles estacionales marcados. Este tipo de planteamientos se siguieron en un trabajo de gran interés sobre *l'Anse de l'Aguillon*, en donde se seleccionó el primer CP de cuatro imágenes MSS de la misma zona, adquiridas en distintas estaciones, abordando posteriormente la clasificación sobre las cuatro fechas (Joly *et al.*, 1983). En forma similar emplean esta técnica otros autores (Maselli *et al.*, 1995; Siljeström y Moreno, 1995). Más original resulta su aplicación para estudiar series temporales de imágenes en estudios sobre cambio global de la vegetación (Eastman y Fulk, 1993), lo que permite obtener, además de las tendencias generales de las cubiertas, información residual de gran interés para detectar anomalías. Posteriormente analizaremos con más detalle el empleo del ACP como técnica para la detección de cambios entre dos imágenes de distinta fecha (ver 3.4.4).

Un problema inherente al ACP es la dificultad de establecer una interpretación *a priori* de los componentes, ya que la transformación es puramente estadística y, por tanto, muy dependiente de las características numéricas de la imagen. Algunos autores sugieren que el primer componente siempre indica el brillo general y el segundo el verdor (Ingebritsen y Lyon, 1985). No obstante, esta afirmación asume que en la imagen existe una cantidad suficiente de cobertura vegetal. De otra forma, el componente de vegetación puede ser el tercero o cuarto. En definitiva, no pueden aplicarse reglas generales para la interpretación de los CP.

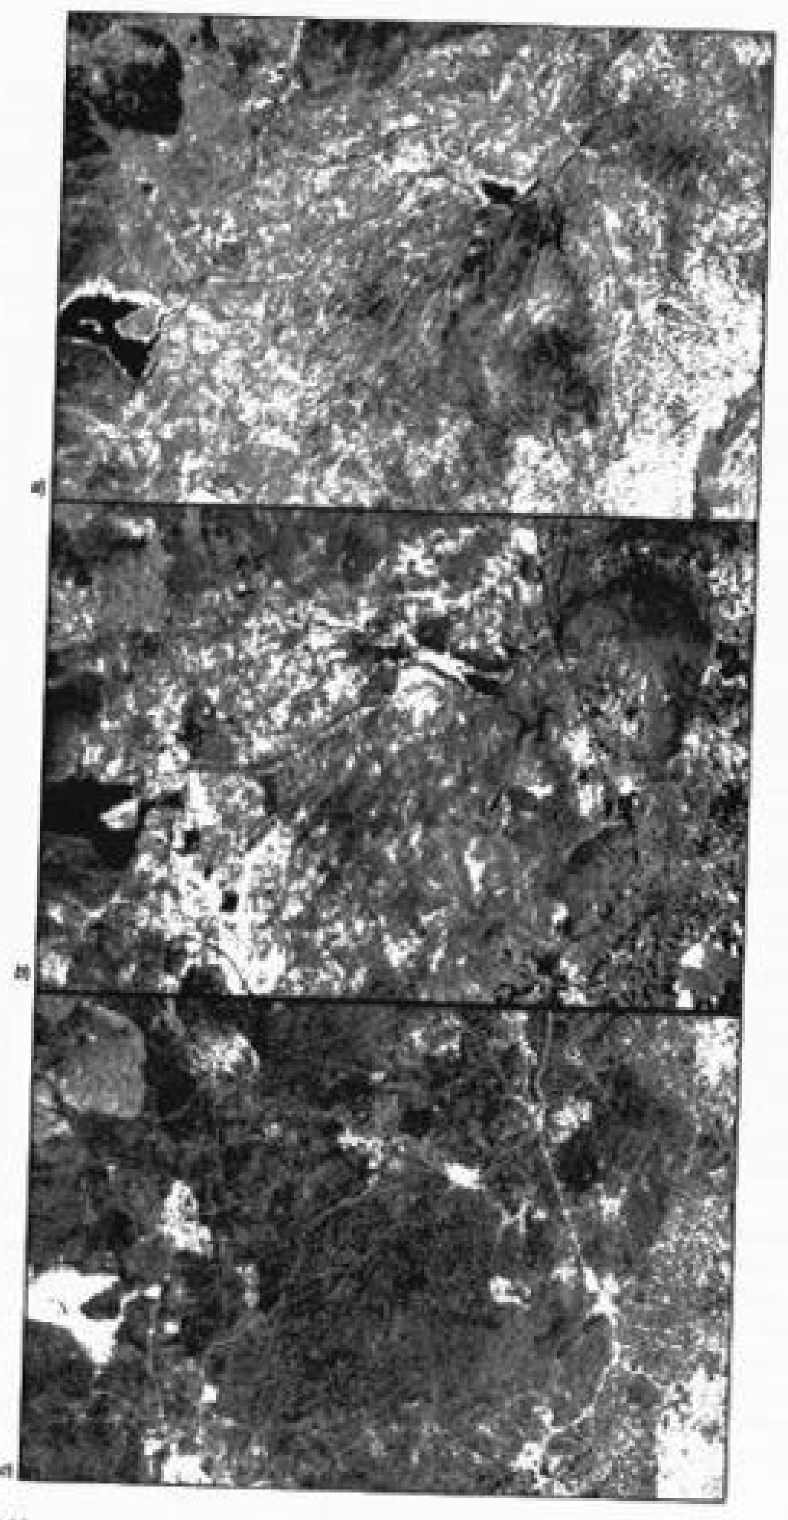


FIG. 7.10. *Componentes principales de la imagen Torrel00: a) CP1; b) CP2; c) CP3.*

1.4. TRANSFORMACIÓN *TASSELED CAP* (TTC)

Al igual que el ACP, esta transformación se dirige a obtener unas nuevas bandas, por combinación lineal de las originales, con objeto de realzar algunos rasgos de interés en la escena. La diferencia frente al ACP estriba en que la TTC ofrece unos componentes de significado físico preciso, esto es, independientes del tipo de imagen que se esté analizando.

La TTC fue ideada por Kauth y Thomas en el marco del proyecto LACIE *(Large Area Crop Inventory Experiment)*, desarrollado por la NASA y el Departamento de Agricultura estadounidense (USDA) en los años setenta, con objeto de mejorar la predicción de cosechas. Dentro de este proyecto se pretendió modelar los componentes fundamentales de variación en una imagen MSS, describiendo sus características físicas desde el punto de vista del seguimiento de cultivos (Kauth y Thomas, 1976). A partir de una serie de imágenes de zonas agrícolas se trató de sintetizar los ejes de variación espectral de los cultivos en una figura tri-dimensional, de aspecto parecido a un gorro con borlas *(tasseled cap)*. Considerando las bandas roja e infrarroja, la base de ese gorro se define por la línea de suelos, en donde se sitúan los distintos tipos de suelo, de acuerdo a su brillo y color (fig. 7.11). Según el cultivo va ganando en vigor, tiende a separarse de la línea del suelo, aproximándose al eje de la banda infrarroja, y convergiendo en un punto cuando se produce la máxima madurez. A partir de ahí el cultivo tiende a marchitarse, retornando hacia la línea de suelos.

La TTC tiende a poner más en evidencia el comportamiento espectral de la vegetación y el suelo, a partir de crear nuevos ejes mejor ajustados a ese espacio físico. En ese nuevo sistema de coordenadas se pretende que sea más nítida la separación entre ambas cubiertas. Para el caso de las imágenes MSS, sobre las que se desarrolló esta transformación, los nuevos ejes se obtuvieron a partir de:

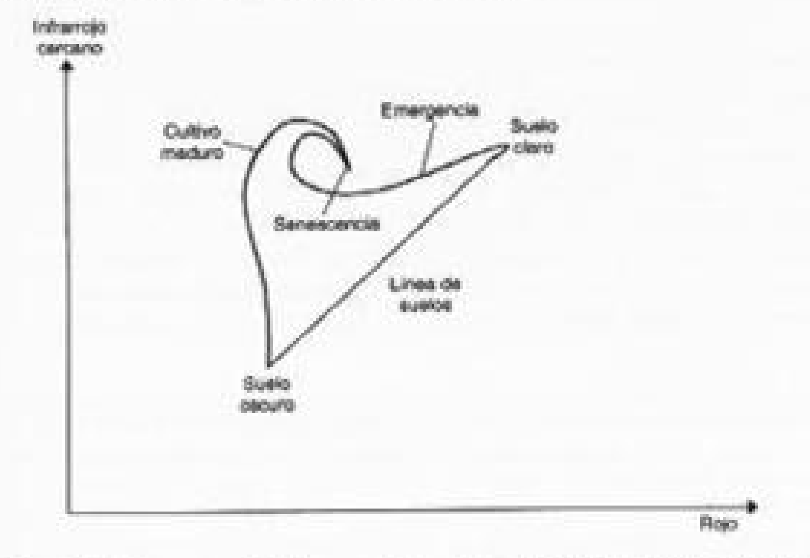


FIG. 7.11. *Evolución temporal de la vegetación en las bandas IRC y R, según el fundamento de la transformación* Tasseled Cap.

$$u_j = R'_i x_i + c \qquad [7.17]$$

donde u_j indicaba el vector correspondiente a la imagen transformada; x_i, el vector de entrada; R'_i, el vector de coeficientes de transformación, y c una constante para evitar valores negativos. Los autores sugerían un valor $c = 32$.

Sobre el conjunto de imágenes de su muestra, los autores del trabajo distinguían tres componentes: uno denominado brillo *(brightness)*, suma ponderada de las cuatro bandas originales; otro, denominado verdor *(greenness)*, relacionado con la actividad vegetativa; un tercero conocido como marchitez *(yellowness)*, que pretendía relacionarse con la reducción en el vigor vegetal, y un cuarto sin significado aparente *(nonsuch)*.

En un primer momento, esta transformación no tuvo mucho eco en la literatura científica, frente a otros índices y transformaciones. En los años ochenta, sin embargo, se empleó con mayor profusión. Crist y Cicone realizaron diversos trabajos a partir de la TTC, mostrando su aplicabilidad a otros sensores, principalmente al TM y AVHRR (Cicone y Metzler, 1984; Crist y Cicone, 1984*a* y *b*). Para el caso del sensor TM, la tabla 7.4 recoge los coeficientes propuestos por Crist y Cicone (1984*b*) para derivar los tres principales ejes de la TTC.

En trabajos comparativos sobre la aplicación de la TTC a imágenes MSS y TM se ha puesto de manifiesto la presencia —en el caso de este último sensor— de un nuevo componente, denominado Humedad *(Wetness)*, estrechamente relacionado con la información que el TM proporciona del SWIR y que resulta original frente al sensor MSS. En consecuencia, una imagen TM presenta tres ejes principales de variación:

1. Brillo *(Brightness)*, que reflgja los cambios en la reflectividad total de la escena. Como puede apreciarse en la tabla 7.4, se trata de una suma ponderada de todos los canales, excluido el térmico.
2. Verdor *(Greenness)*, que indica el contraste entre las bandas visibles y el IRC. Destaca la intervención de la banda 4, la ponderación negativa de las visibles y la anulación mutua de las dos en el infrarrojo-medio.
3. Humedad *(Wetness)*, que se relaciona con el contenido de agua en la vegetación y en el suelo, y se marca por el contraste entre el SWIR, en donde se manifiesta con mayor claridad la absorción del agua, y el resto de las bandas. Otros autores han propuesto denominar a este componente *Maturity*, puesto que se ha encontrado una clara relación entre él y la madurez de la cubierta vegetal. Por ejemplo, en un inventario forestal desarrollado en Oregón se obtuvieron muy buenas correlaciones entre este componente y algunas variables forestales medidas en el terreno, siendo un magnífico

TABLA 7.4. *Coeficientes propuestos para la obtención de la TTC a partir de una imagen Landsat-TM (Crist y Cicone, 1984b)*

	B1	*B2*	*B3*	*B4*	*B5*	*B7*
Brillo	0.3037	0.2793	0.4743	0.5585	0.5082	0.1863
Verdor	–0.2848	–0.2435	–0.5436	0.7243	0.0840	–0.1800
Humedad	0.1509	0.1973	0.3279	0.3279	–0.7112	–0.4572

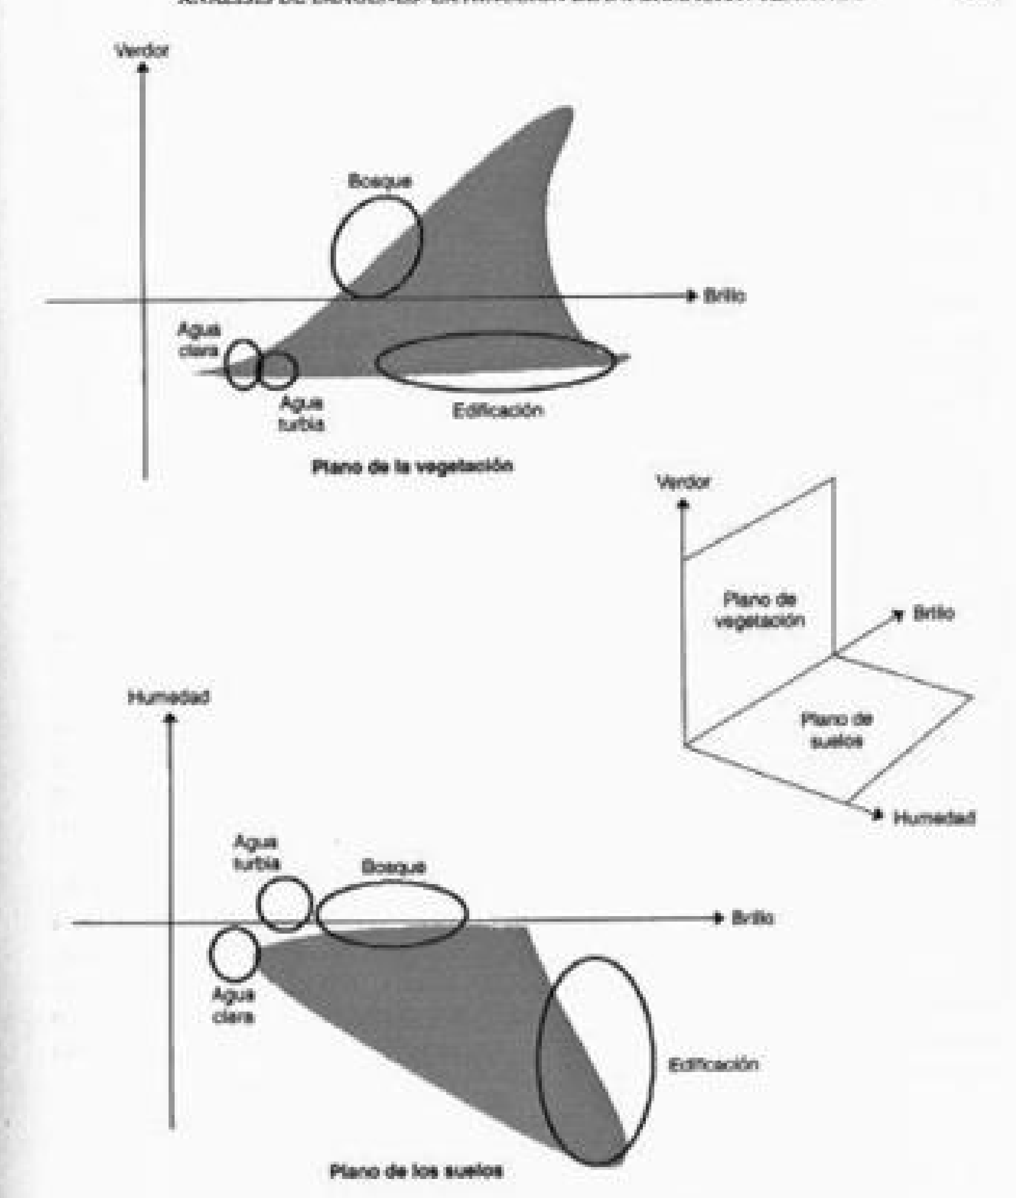


FIG. 7.12. *Planos de variación en la TTC.*

indicador de la edad y densidad de la cobertura forestal. Además se observó que era el componente menos afectado por la topografía (Cohen y Spies, 1992).

La combinación de estos ejes permite distinguir varios planos de variación (fig. 7.12), de gran interés para el estudio detallado de suelos y vegetación. En este sentido, suelen distinguirse tres planos: el de vegetación, formado por el eje de brillo y de verdor, el de suelos, formado por el brillo y la humedad, y el de transición, formado por la humedad y el verdor (Crist y Cicone, 1984*b*).

Una de las ventajas de esta transformación frente al ACP radica en su interpretabilidad física. En efecto, los componentes deducidos a partir de la TTC tienen un significado preciso, independiente de las condiciones de la escena, puesto que se apoyan sobre las características del sensor y no sobre la radiometría de la imagen. Por tanto, los coeficientes propuestos pueden aplicarse a distintas imágenes del mismo sensor, con las salvedades propias de considerar que fueron extraídos a partir de los rasgos agrícolas del *Mid-West* americano.

La TTC cuenta ya con un importante rango de aplicaciones (Cicone y Metzler, 1984; Crist y Cicone, 1984*b*; García *et al.*, 1986; Perry y Lautenschlager, 1984). De modo esporádico se ha utilizado para la corrección atmosférica (Labuto, 1991) y para homogeneizar radiométricamente una serie multitemporal de imágenes (Hall *et al.*, 1991*a*).

Hemos aplicado los coeficientes propuestos por Crist y Cicone a la imagen Torrel00 para derivar los componentes de la TTC (fig. 7.13). El primero de los componentes deducidos, conocido como Brillo, aparece como una imagen pancromática, por cuanto se trata de una combinación ponderada de las diferentes bandas. En este sentido, presenta rasgos muy similares al primer componente del ACP. El componente de Verdor refleja con gran claridad los dominios vegetales presentes en la imagen. Destaca el contraste entre los espacios edificados y suelos desnudos frente a las cubiertas vegetales, principalmente en los cultivos y el pastizal, aunque también resultan evidentes las urbanizaciones ajardinadas. Los tonos más oscuros aparecen en suelos descubiertos, áreas edificadas y vías de comunicación (nacional de Burgos, carretera de Colmenar, Manzanares-Soto). Por último, el componente de Humedad manifiesta con claridad los cursos y láminas de agua, así como algunos sectores de vegetación con sombra y núcleos residenciales. Los tonos más oscuros se presentan en los suelos descubiertos.

La composición en color de estos tres componentes (fig. 14*) ofrece una tonalidad relativamente similar a la que observamos para los componentes principales de la imagen. Se muestran también las áreas de vegetación en colores verdes, para los pastizales, y cian para los pinares (por su mayor contenido de sombra-humedad); las láminas de agua siguen apareciendo en azul, y los suelos descubiertos en rojo intenso (alto brillo, bajo verdor y humedad), salvo las áreas urbanas que ofrecen una tonalidad más magenta por la mayor proporción de sombras.

1.5. Transformación IHS

En el capítulo anterior vimos los fundamentos de la formación del color en un sistema de ADI, indicando que estas composiciones se basan en la mezcla de tres cañones de color elementales: rojo, verde y azul (RVA). Una forma alternativa de representar el color hace referencia, no a sus componentes sino a sus propiedades. Se trata de la transformación Intensidad, Tono, Saturación (IHS, *Intensity, Hue, Saturation*), de reciente empleo en teledetección, pero que ya ha mostrado su interés para mejorar la discriminación de algunos rasgos de marcado carácter cromático (Koutsias *et al.*, 2000; Terhalle y Bodechtel, 1986) y para combinar imágenes adquiridas por distintos sensores, como luego veremos.

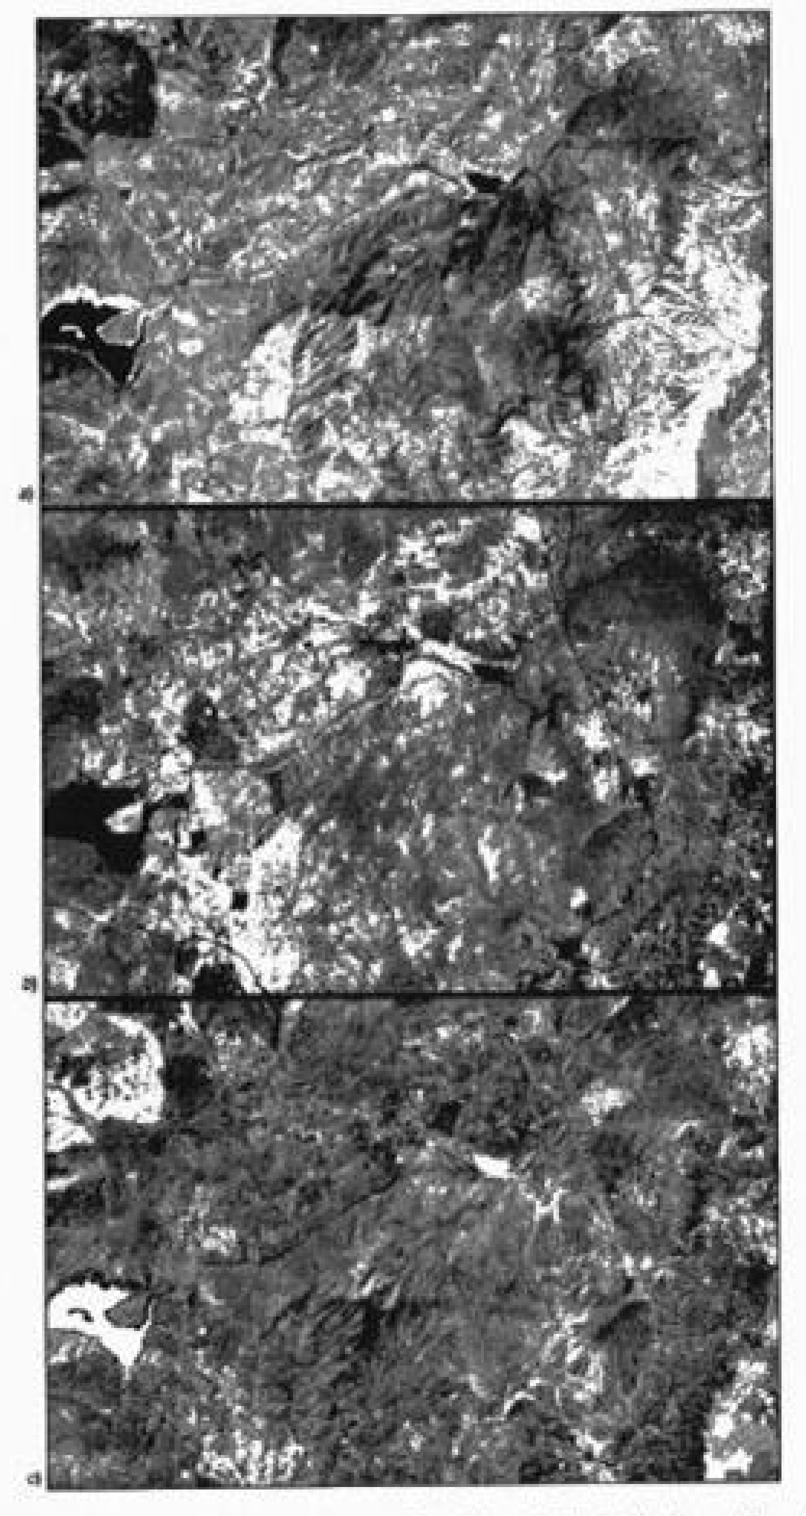
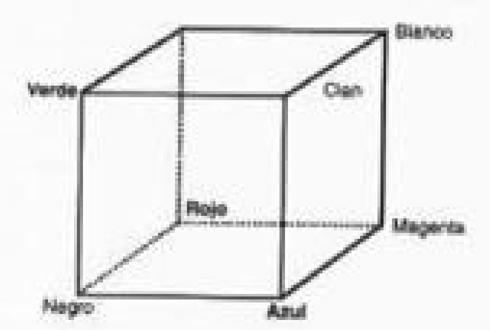


FIG. 7.13. *Componentes TTC de la imagen Torrel00: a) Brillo; b) Verdor; c) Humedad.*



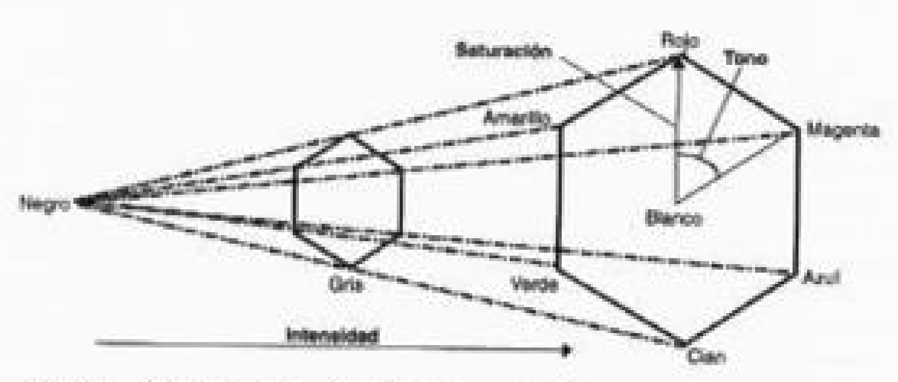


FIG. 7.14. *Representación gráfica del color a partir de las coordenadas RGB e IHS.*

El tono procede de la longitud de onda en donde se produce la máxima reflectividad del objeto: equivale al color que aprecian nuestros ojos. La saturación refiere a la pureza de dicho color, su grado de mezcla con los otros colores primarios. Por último, la intensidad puede identificarse con el brillo, en función del porcentaje de reflectividad recibido.

Es posible transformar las coordenadas de la imagen de los colores primarios (RVA) a las propiedades del color (IHS). En el primer caso, cada píxel puede representarse en un diagrama tridimensional (cada eje define uno de los colores primarios). En el segundo, por un hexágono, en donde la cara hexagonal sería el tono, el eje vertical la saturación, y la distancia al eje vertical la intensidad (fig 7.14). La transformación entre coordenadas RVA y IHS puede abordarse gracias a distintos algoritmos de conversión (Pellemans *et al.*, 1993). En primer lugar es necesario partir de una combinación de bandas determinada, que se convertirá a las coordenadas IHS. Denominaremos ND_r, ND_v y ND_a a los ND asignados al rojo, verde y azul, respectivamente. A partir de ellos se calcula la Intensidad (I) como la media de los tres:

$$I = \frac{ND_r + ND_v + ND_a}{3} \qquad [7.18]$$

El tono se calcula como:

$$T = \arctan\left(\frac{2\,ND_r - ND_v - ND_a}{\sqrt{3}(ND_v - ND_a)}\right) + C \qquad [7.19]$$

donde:

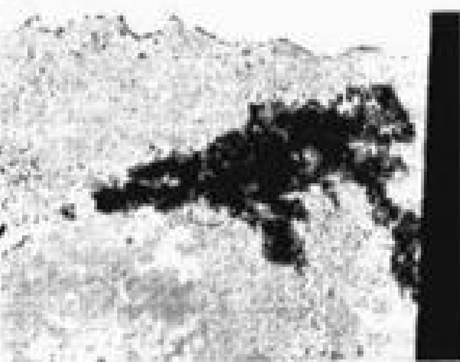
$$C = 0, \text{ si } ND_v \geq ND_a$$
$$C = \pi, \text{ si } ND_v < ND_a$$

y la saturación como:

$$S = \frac{\sqrt{6}}{3}\sqrt{ND_a^2 + ND_v^2 + ND_r^2 - ND_a\,ND_v - ND_a\,ND_r - ND_v\,ND_r} \qquad [7.20]$$

Como ya comentamos, la transformación IHS ha sido bastante utilizada con fines geológicos. Por ejemplo, Terhalle y Bodechtel (1986) ilustran el uso de esta transformación para la cartografía de rasgos morfológicos en zonas áridas. También se ha empleado con éxito en la determinación de áreas quemadas, gracias al muy bajo contraste cromático que presenta la vegetación quemada frente a otras cubiertas terrestres (Koutsias *et al.*, 2000: fig. 7.15). Sin embargo, donde mas aplicación ha tenido esta







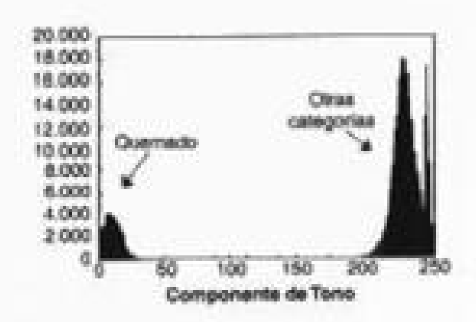


FIG. 7.15. *Empleo de la transformación IHS para discriminar áreas quemadas.* (Adaptado de Koutsias *et al.*, 2000.)

técnica es la referida a la fusión de imágenes de distintos sensores. Para facilitar una exposición más ordenada dejaremos este comentario para el epígrafe dedicado a este tipo de técnicas (7.1.7).

Un ejemplo de transformación IHS puede analizarse en la figura 7.16 correspondiente a nuestra imagen de ejemplo. La composición original corresponde a un falso color mejorado (ETM+ 4/5/3, RVA), a partir del cual se han generado los tres componentes físicos: Tono, Saturación e Intensidad. La imagen de Intensidad ofrece un aspecto similar al componente de brillo de la TTC, al mostrar las tendencias promedio en las tres bandas más importantes del sensor ETM+. El Tono ofrece los valores más altos para la superficie urbana y el agua, lo que indica que el color dominante de la imagen original corresponde a las superficies más reflectivas en las bandas 3 y 5. La correspondiente a Saturación muestra también valores altos para el agua, mientras la ciudad y suelos desnudos aparecen en grises oscuros o negros. La vegetación ofrece valores altos en este componente, como consecuencia de su clara cromaticidad.

1.6. Técnicas de análisis hiperespectral

Como ya vimos en el capítulo 3, la resolución espectral de los sensores espaciales había estado severamente restringida hasta hace muy pocos años, cuando se han comenzado a lanzar al espacio los primeros sensores hiperespectrales. Hasta entonces, las técnicas de tratamiento de este tipo de datos estaban restringidas a las imágenes adquiridas por sensores aeroportados, y más en concreto por el AVIRIS *(Airborne Visible/Infrared Imaging Spectrometer)*, sin duda el sensor hiperespectral que ha supuesto un mayor avance en esta disciplina. El lanzamiento del MODIS en 1999, y del Hyperion, en 2000, han abierto las puertas al empleo de estas técnicas a partir de teledetección espacial. Las perspectivas son muy halagüeñas en este sentido, ya que están previstas otras plataformas espaciales que facilitarán en breve imágenes hiperespectrales (MERIS a bordo del Envisat, *Warfighter* a bordo del Orbview-4, o el australiano ARIES, además de la continuación de los proyectos ya activos de la NASA).

Lo que caracteriza a este tipo de sensores, como su propio nombre indica, es su muy alta resolución espectral, que les permite adquirir un espectro bastante continuo de cualquier píxel observado en terreno (fig. 7.17). Además del notable incremento de los datos a procesar que esto implica (unas 40 veces más datos por píxel que con un sensor convencional: Richards y Xia, 1999), esa detallada definición de cada píxel nos permite introducir tratamientos bastante específicos a partir de estas imágenes, que no serían abordables si contáramos sólo con unas pocas bandas. Por esta razón, nos ha parecido conveniente dedicarle un epígrafe propio dentro de esta obra, si bien algunas de las técnicas presentadas, como veremos en su comentario, podrían también emplearse en sensores más convencionales.

1.6.1. *Análisis de espectros*

Como hemos comentado, la primera característica que define una imagen hiperespectral es la gran cantidad de bandas que contiene (habitualmente en el orden de va-

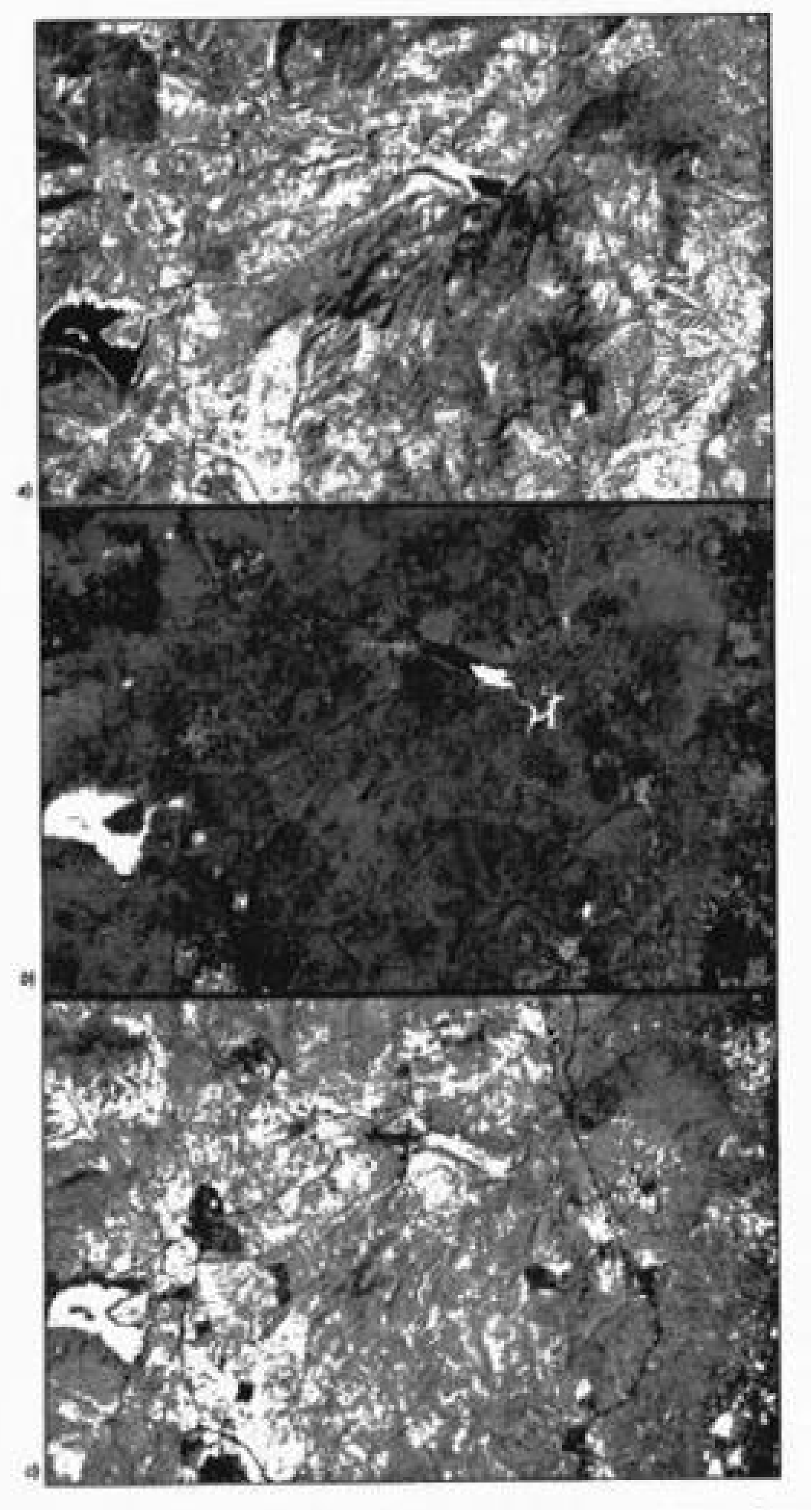


FIG. 7.16. *Componentes IHS de la imagen Torrel00: a) Intensidad; b) Tono; c) Saturación.*

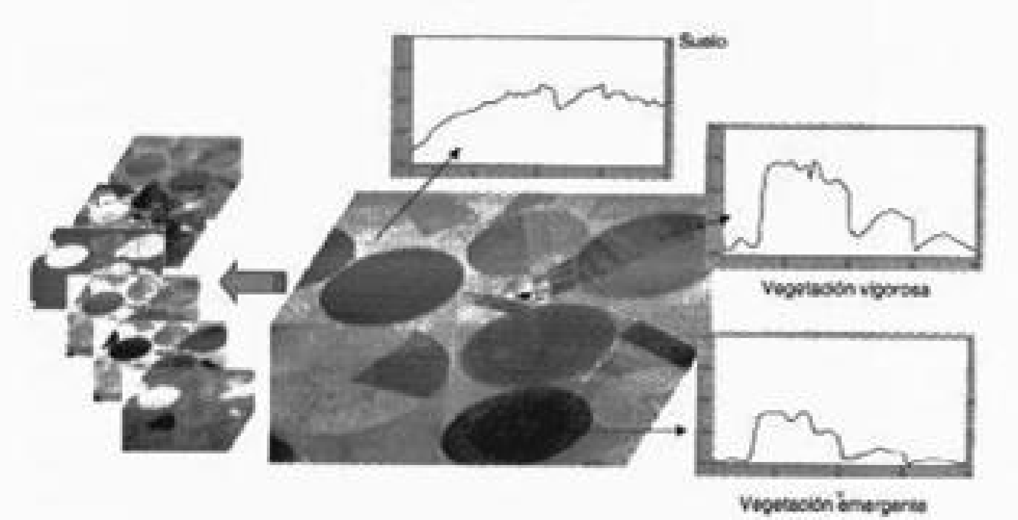


FIG. 7.17. *Concepto de imágenes hiperespectrales.*

rias decenas a centenas). Esto le permite definir, en la mayor parte de los casos, espectros continuos para cada píxel de la imagen,[3] de forma similar a las curvas que podemos obtener con un espectro-radiómetro de laboratorio, con la diferencia de que en este caso sólo medimos un punto, mientras la imagen nos proporciona una representación bidimensional de los espectros.

En consecuencia, la forma más elemental de analizar una imagen hiperespectral sería comparar los espectros que de ella se derivan con los que podemos obtener a partir de equipos de laboratorio, o de las bibliotecas espectrales disponibles al público (cap. 2, apdo. 5.5). Lógicamente, esto supone convertir previamente los ND originales en valores de reflectividad, para lo que es preciso aplicar la calibración y las correcciones atmosféricas y topográficas oportunas. A partir de ahí puede identificarse la cubierta de un píxel comparando su espectro con otros de referencia, aplicando alguna técnica que permita ver a cuál es más similar. Entre los métodos disponibles vamos a comentar dos comunes: la codificación binaria y la absorción diferencial.

La codificación binaria es una sencilla técnica que calcula, para cada banda espectral, si la reflectividad observada es mayor o menor a la reflectividad media de ese espectro, asignándole un valor 0 si es inferior y 1 si es superior. Si dos espectros son similares tenderán a presentar la misma cadencia de ceros y unos a lo largo de las distintas bandas que forman esos espectros. Por tanto, al comparar la codificación binaria de un espectro desconocido con otro de referencia que corresponda a la misma cubierta obtendríamos un elevado porcentaje de parejas 0-0 o 1-1 (Mazer *et al.*, 1988). Para cuantificar la similitud entre espectros podemos calcular un sencillo índice que denominamos índice de acuerdo espectral (IAE):

3. Decimos en la mayor parte y no en todos, pues puede haber sensores hiperespectrales, por tener muchas bandas, que no tomen espectros continuos, ya que esas bandas no son contiguas. Éste es el caso del MODIS.

$$\mathrm{IAE} = \frac{\sum_{k=1,m} (\mathrm{CB}_{i,k} - \mathrm{CB}_{j,k})^2}{m} \qquad [7.21]$$

donde $CB_{i,k}$ indica la codificación binaria (0/1) del espectro i (el que queremos identificar) para la banda k, m el número de bandas, y $CB_{j,k}$ la codificación del espectro de referencia para la misma banda. Cuanto más cercano a 0 el IAE, los espectros serán más similares y cuanto más próximos a 1, más distintos. En la figura 7.18 pueden observarse unos espectros extraídos de una imagen hiperespectral tomada por el sensor Hymap en la zona agrícola de Barrax (Albacete) en junio de 1999. Este sensor cuenta con 128 bandas comprendidas entre 0,4 y 2,5 μm.

En la figura 7.18 se han representado tres espectros extraídos de la imagen: uno corresponde a vegetación vigorosa (cultivos de alfalfa en este caso), otro a suelo agrícola descubierto, y un tercero que nos interesa clasificar. A simple vista se observa que tiene mayores afinidades con el espectro de vegetación, pero conviene cuantificar esa similitud, además de servirnos de ejemplo para ilustrar el concepto de codificación binaria. A la derecha de los espectros, en la misma figura, se inserta la codificación correspondiente a los espectros de vegetación, suelo y píxel objetivo (el que queremos asignar). Se confirma que el patrón espectral es mucho mas similar al espectro de vegetación que al de suelo. El valor del IAE para el espectro de vegetación es 0,039 y para el suelo es 0,5625, confirmándose la mejor asignación a la clase vegetación.

En la misma línea de la codificación binaria se encuentra la técnica denominada *continuum removal* (Kruse *et al.*, 1993*b*), que podríamos traducir como análisis de absorción diferencial frente a la tendencia. Se trata de señalar en cada espectro una serie de valores culminantes, que marquen los valores máximos de reflectividad en distintos segmentos del espectro (máximos locales). Estos máximos sirven para señalar las tendencias del continuo. Estos valores se utilizan para normalizar los espectros extraídos de la imagen y/o de una biblioteca espectral de referencia dividiendo estos valores por los de la tendencia, lo que permite eliminar el efecto del albedo, reduciendo la principal fuente de variación de una imagen y centrándonos en lo que específico de cada banda (la absorción diferencial). Comparando las bandas de absorción con las que ofrezca otro espectro de referencia podrá asignarse un determinado píxel hiperespectral a una categoría de interés. Esta técnica se ha desarrollado con bastante éxito en imágenes AVIRIS para la exploración minera (Kruse *et al.*, 1993*a*).

Además de la longitud de onda promedio de esas bandas de absorción también es interesante analizar cuál es la intensidad de la absorción, que vendría dada por la «profundidad» o, lo que es lo mismo, la magnitud de la diferencia frente a la tendencia, así como su anchura y asimetría. Estos rasgos facilitan el análisis de un espectro desconocido, delimitando rasgos de gran interés para determinar sus propiedades biofísicas (un reciente ejemplo, en el ámbito de la estimación del contenido de agua en cultivos puede consultarse en Tian y Tong, 2001). La figura 7.19 incluye un ejemplo de este tipo de gráficos, para el caso específico del espectro de vegetación que hemos visto previamente. En este caso se observan una serie de bandas de clara absorción centradas principalmente en torno a 0,46, 0,65, 1,4 y 1,9 μm.

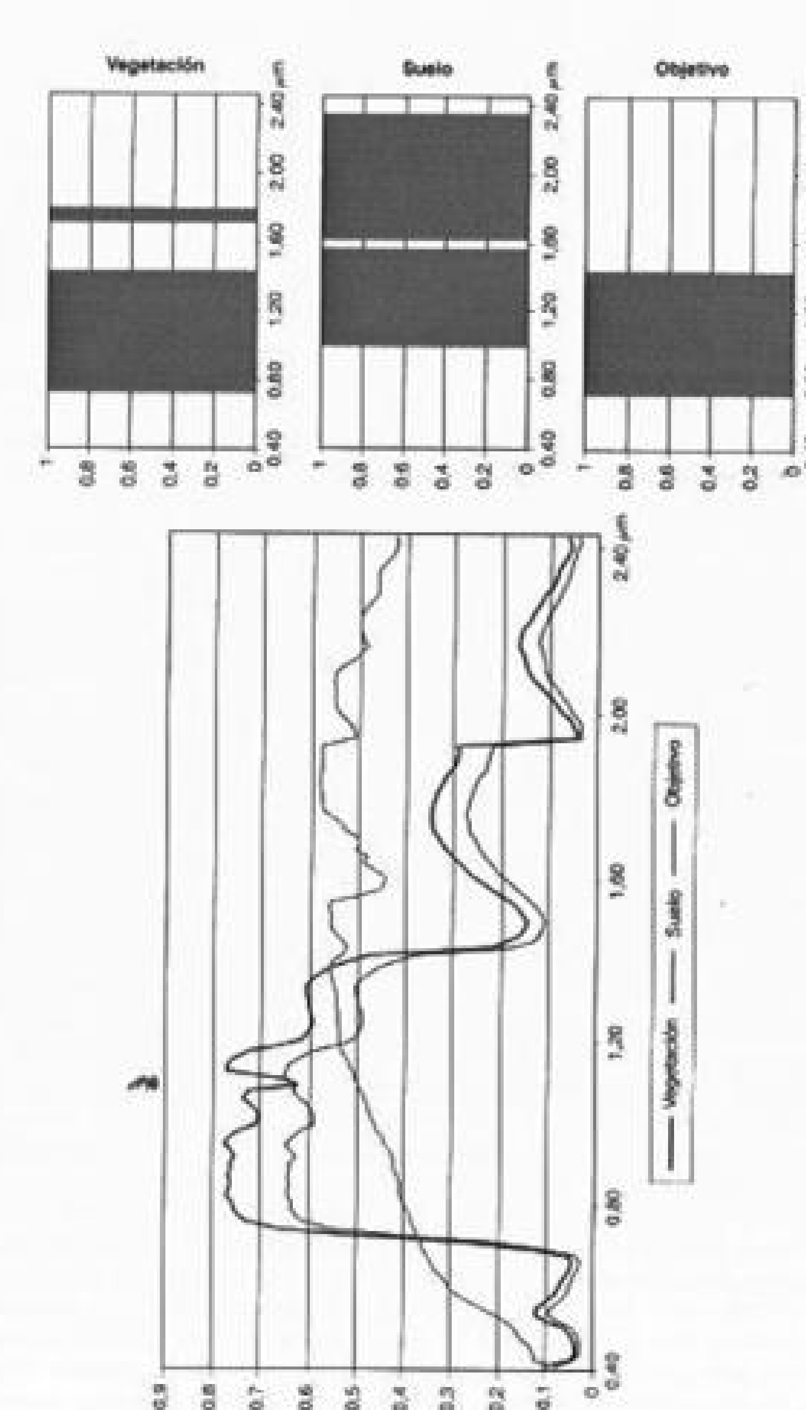


FIG. 7.18. *Codificación binaria de tres espectros extraídos de la imagen Barrax90.*

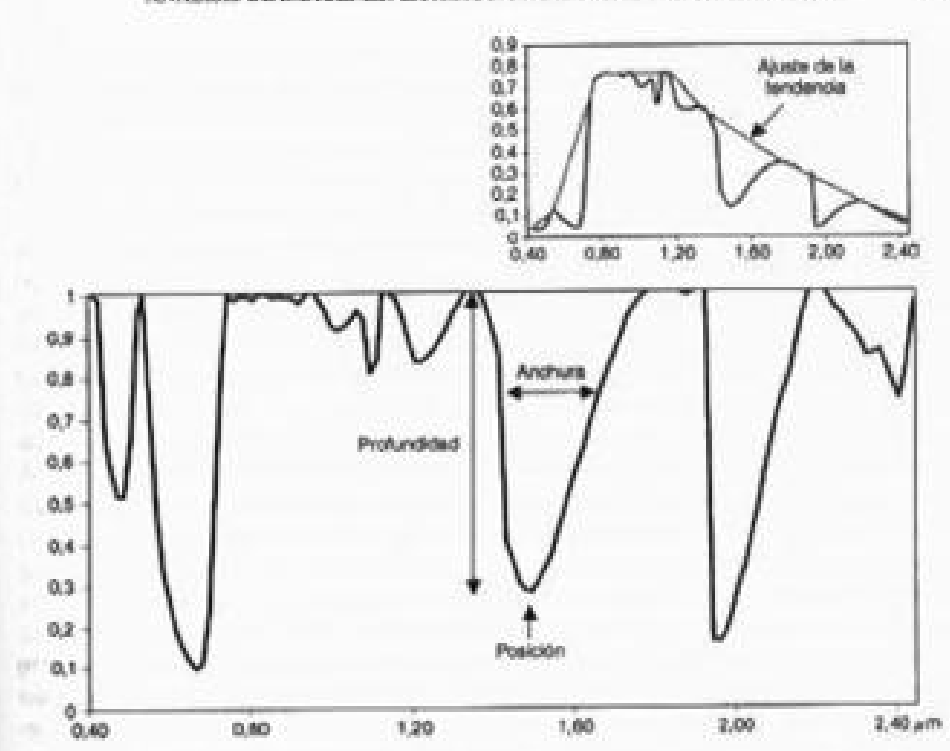


FIG. 7.19. *Ejemplo de análisis de la absorción por diferencias frente a la tendencia (espectro de vegetación).*

1.6.2. *Clasificación angular*

Supone otra técnica alternativa para el análisis de espectros, por lo que propiamente cabría incluirlo en el anterior epígrafe. Ahora bien, puesto que para otros autores supone una alternativa a las técnicas estadísticas de clasificación que luego comentaremos, también cabe considerarla como un apartado específico.

El clasificador angular (*Spectral Angle Mapper*, SAM) calcula la similitud entre dos espectros a partir de su desviación angular, asumiendo que forman dos vectores en un espacio m-dimensional (siendo *m* el número de bandas disponibles). En síntesis, se trata de un método para comparar espectros desconocidos con otros de referencia, ya sean tomados de la propia imagen, ya de bibliotecas espectrales. Puesto que esta técnica calcula la dirección relativa entre espectros, tiene la ventaja de ser bastante independiente de las condiciones de iluminación, ya que éstas hacen referencia a la longitud del vector pero no a su posición, y por tanto los ángulos no cambian aunque cambie el albedo.

El algoritmo determina la similitud entre dos espectros calculando el ángulo espectral que los separa (θ):

$$\theta = \arccos \frac{\sum_{k=1,m} ND_{i,k}\, ND_{j,k}}{\sqrt{\sum_{k=1,m} ND_{i,k}^2}\,\sqrt{\sum_{k=1,m} ND_{j,k}^2}} \qquad [7.22]$$

siendo $ND_{i,k}$ el valor del píxel i (el espectro objetivo) en una determinada banda k de la imagen, $ND_{j,k}$ el del espectro de referencia j en la misma banda, y m el número de bandas. El criterio puede utilizarse para comparar pares de espectros determinados, por ejemplo, muestras de suelos con distintos contenidos de materia orgánica, o para asignar un píxel desconocido a una clase de referencia en una clasificación temática. En este caso, el píxel i se asignará a la clase de referencia j con un valor θ más pequeño. Lógicamente, también pueden compararse los cosenos entre vectores, eliminando en la fórmula anterior la necesidad de calcular el arcoseno. Lo habitual para imágenes hiperespectrales es trabajar con valores de reflectividad, pero hemos indicado en su lugar ND ya que éstos pueden estar escalados de la forma que estime oportuno el intérprete, siempre que, como es lógico, tengan la misma métrica los de referencia y los que se pretenden clasificar.

La figura 7.20 presenta un esquema del clasificador angular, para un caso sencillo de tres bandas. Aunque se ha desarrollado en el marco del análisis hiperespectral, esta técnica también puede aplicarse a un menor número de bandas, siendo una alternativa a los clasificadores convencionales, que luego comentaremos.

1.6.3. *Reducción de la dimensionalidad de la imagen*

Contar con un amplio número de bandas, no cabe duda, tiene un gran interés, pero también lleva consigo una serie de dificultades, tanto en lo que se refiere al almacenamiento y proceso de la información, como a posibles problemas estadísticos que surgen cuando las variables analizadas tienen una alta correlación entre sí (Mather, 1998). Para paliar estos dos problemas (almacenamiento y redundancia) se recomienda con frecuencia utilizar alguna técnica de compactación de datos, que permita retener la mayor parte de la información original en un menor número de bandas. Con esta finalidad se utilizan varias técnicas, que pretenden retener la información más significativa contenida en la imagen hiperespectral.

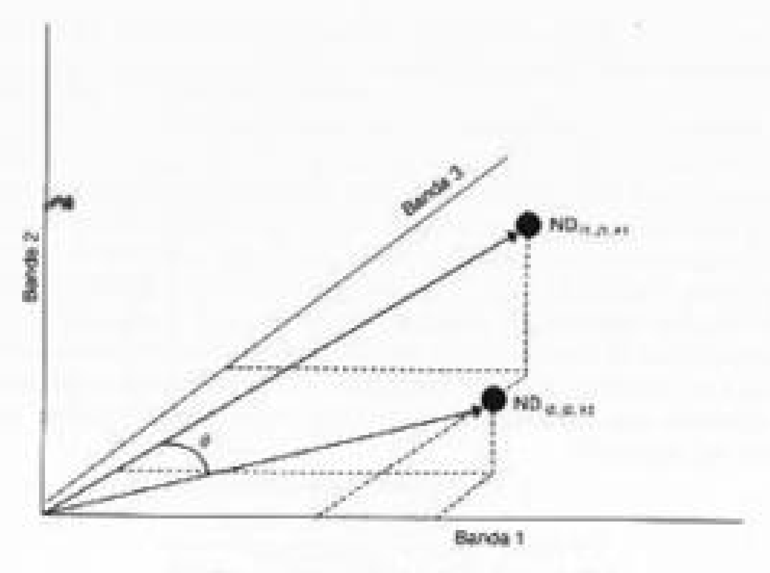


Fig. 7.20. *Esquema del clasificador angular.*

Una de las más conocidas está basada en el análisis de componentes principales (ACP), que comentamos anteriormente. Se denomina Fracción de Mínimo Ruido (MNF, *Minimum Noise Fraction*), y consiste en aplicar dos ACP consecutivos: el primero, basado sobre una estimación de la matriz de covarianza del ruido, permite eliminar redundancias y re-escalar el ruido de los datos; el segundo es un ACP convencional de los datos ya depurados. El ruido se estima a partir de los componentes más marginales de los autovalores, centrando el análisis en aquellos que retienen la mayor parte de la información original (Green *et al.*, 1988).

Otra técnica de reducción del ruido en imágenes hiperespectrales es la denominada análisis en primer y segundo plano (FBA, *Foreground/Background Analysis*), en donde los espectros se dividen en dos grupos (primer y segundo plano). En el primer plano se coloca la información que nos interesa realzar y se proyecta en el eje de unos, mientras la información de menor interés se proyecta sobre ceros. De esta forma se recogen las principales fuentes de variación en las características que pretenden medirse. Se proyectan estos dos grupos de tal manera que se maximicen las diferencias entre ellos, minimizando la diferencia en el interior de los grupos. Esto se hace definiendo un vector de pesos para cada banda que tienda a equiparar a 1 los espectros del primer plano y a 0 los del segundo. La técnica se utilizó con éxito para estimar algunas variables biofísicas de las hojas a partir de espectros de laboratorio para distintas especies vegetales (Pinzón *et al.*, 1998).

1.6.4. *Análisis lineal de mezclas espectrales*

El análisis lineal de mezclas espectrales (ALME)[4] parte de asumir que la señal captada para un determinado píxel puede ser una mezcla de las reflectividades procedentes de varias cubiertas, en función de la superficie que ocupan en ese píxel, y pretende obtener precisamente esas proporciones. Por tanto, como fruto de esta técnica obtendremos tantas imágenes de salida como categorías pretendan estudiarse. En cada una de ellas, el ND de un determinado píxel indicará el porcentaje de superficie que ocupa esa categoría (fig. 7.21).

Tradicionalmente la clasificación de imágenes de satélite ha tenido por misión asignar cada píxel a una, y sólo una, de las categorías previamente definidas en la leyenda de trabajo. Con ser de gran interés este planteamiento, como veremos en el próximo apartado, resulta un enfoque algo limitado para ciertas aplicaciones. La necesidad de categorizar cada píxel de la imagen con un código exclusivo implica asumir que ese píxel es homogéneo o, dicho de otra forma, que toda su superficie está cubierta por la categoría a la que se ha asignado. En definitiva, esa clasificación de la imagen no considera que la radiancia proveniente de un píxel, en la mayor parte de las ocasiones, es una mezcla de distintas cubiertas, y que al clasificarlo simplemente optamos por asignarlo a la cubierta dominante. A efectos de la representación cartográfica convencional, éste es el objetivo habitual, ya que los mapas temáticos asumen que cada uni-

4. En inglés se utilizan los términos *Spectral Mixture Analysis* (SMA) o *Linear Mixture Analysis* (LMA).

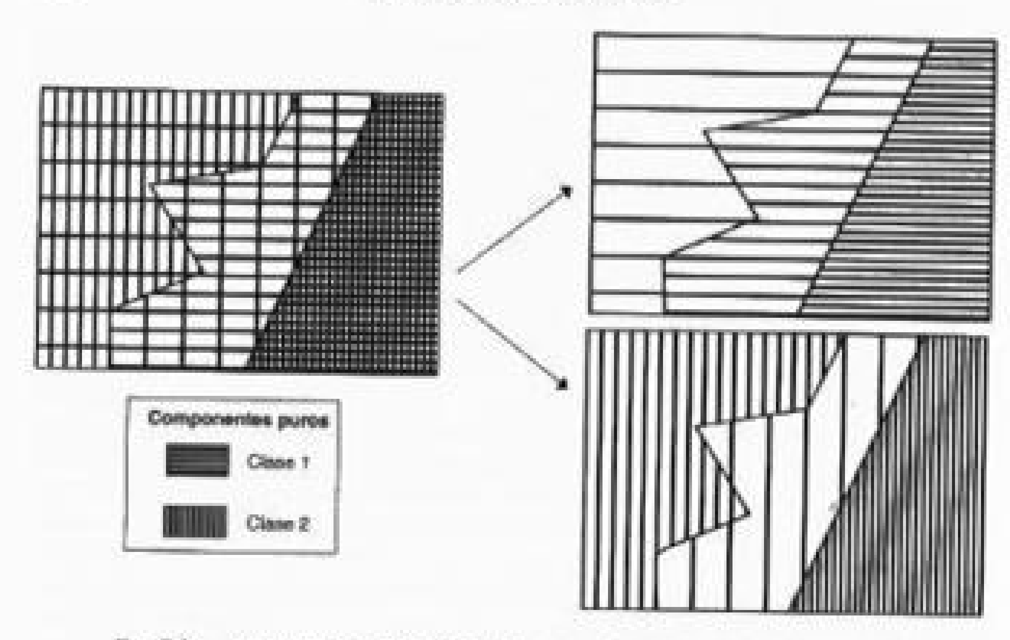


FIG. 7.21. *El ALME pretende extraer las proporciones presentes en cada píxel de unas determinadas categorías o componentes puros.*

dad es homogénea: una misma parcela no puede asignarse a dos o más categorías. Cuando en realidad existe esa mezcla, que va más allá de la mínima unidad cartografiable a una determinada escala, las opciones más empleadas son, o bien simplificar la realidad, prescindiendo de las categorías menos representativas, o bien generar categorías mixtas, en donde la realidad se etiqueta considerando esa difícil separación en componentes. Las denominaciones «mosaico de cultivos» o «matorral arbolado» son ejemplos de este segundo enfoque.

Una alternativa a ambos planteamientos es emplear técnicas que permitan extraer información sobre el grado de mezcla presente en cada píxel. En otras palabras, se trataría de obtener imágenes que nos indiquen la proporción de cada categoría de interés en un píxel, asumiendo que la respuesta recibida por el sensor es, de alguna forma, una combinación de signaturas espectrales puras. La obtención de estos componentes sub-píxel no es una tarea reciente en teledetección, pues ya se ofrecen soluciones de gran interés en los años setenta (Marsh *et al.*, 1980). Sin embargo, a partir de los años noventa se extendió su empleo, especialmente a partir del uso masivo de imágenes de baja resolución espacial, como las proporcionadas por el AVHRR, en donde es especialmente crítico obtener información sobre la mezcla en el interior de un píxel.

El ALME parte de algunos supuestos que conviene considerar antes de analizar el gran potencial de esta técnica, pues también nos ayudarán a valorar sus limitaciones. En primer lugar se asume que la radiación recibida por el sensor desde cada tipo de cubierta se restringe al ámbito de la parcela ocupada por ese píxel; en otras palabras, que no está influyendo en la radiación reflejada la señal procedente de una cubierta vecina (Settle y Drake, 1993). En caso de píxeles que contengan más de un tipo de cubierta, la

segunda asunción considera que su radiancia global es proporcional a la superficie ocupada por cada cubierta. Esto equivale a que no exista una cubierta que tienda a, por decirlo así, «ensombrecer» al resto, provocando una ponderación superior a su propia superficie en la radiación finalmente reflejada al sensor. La linealidad de la mezcla es asumible sólo en las bandas del espectro óptico, no en el térmico. Por último, y más importante aún, se asume en el ALME que existen signaturas espectrales puras, válidas para toda la zona analizada (Quarmby *et al.*, 1992).

Si estas tres suposiciones son admisibles podemos asumir que la reflectividad de un determinado píxel con mezcla es una combinación lineal de la reflectividad característica de unas cubiertas o componentes básicos (que denominaremos componentes puros o miembros terminales: *endmembers*), en proporción equivalente a la superficie que ocupan. En definitiva, se cumple la fórmula siguiente (Shimabukuro y Smith, 1991):

$$\rho_{i,j,k} = \Sigma_{m=1,p} F_{i,j,m}\, \rho_{m,k} + e_{i,j} \qquad [7.23]$$

donde $\rho_{i,j,k}$ indica la reflectividad observada en el píxel i,j en la banda k; $F_{i,j,m}$ es la proporción del componente m en ese píxel i, j para cada uno de los p componentes puros; $\rho_{m,k}$ corresponde a la reflectividad característica de ese componente m en la banda k, y $e_{i,j}$ es un término del error asociado a la estimación de las proporciones en cada píxel i, j.

Esta fórmula está sujeta a dos restricciones. Por un lado, la proporción de cada componente puro (F_m) debe estar entre 0 y 1:

$$0 \leq F_{i,j,m} \leq 1 \qquad [7.24]$$

esto es, no puede haber proporciones negativas, y

$$\Sigma_{m=1,p} F_{i,j,m} = 1 \qquad [7.25]$$

la suma de las proporciones para todas los componentes es igual a la superficie total del píxel.

La ecuación [7.23] también puede expresarse en términos de ND, en lugar de reflectividad, siempre que no se modifique la linealidad frente a la información inicialmente detectada por el sensor. El interés de presentar la fórmula en magnitudes físicas se relaciona con la primera fase, y más importante, del ALME: definir con precisión los componentes puros de los que van a obtenerse las imágenes «desmezcladas». Estos componentes son los tipos característicos de cubierta que explican la señal reflejada hacia el sensor. Se asume que el resto de situaciones que se presenten en la imagen son mezcla de ellas. Por ejemplo, los componentes puros podrían ser la vegetación sana, el suelo y las sombras, para un estudio de deforestación (Adams *et al.*, 1995; Holben y Shimabukuro, 1993); las plantaciones forestales vigorosas, las recientemente cortadas y las que ofrecen un proceso de regeneración, en el caso de un estudio forestal (Hlavka y Spanner, 1995); la vegetación sana, la quemada y las sombras, para una cartografía de incendios forestales (Caetano *et al.*, 1994), o los tipos de cultivo para un inventario de cosechas (Quarmby *et al.*, 1992). Los más habituales han sido los de vegetación vigorosa, suelo y sombra, si bien otros autores re-

comiendan añadir a estos tres básicos un cuarto correspondiente a vegetación seca (o no fotosintética: Riaño *et al.*, 2001*b*; Roberts *et al.*, 1993).

Una limitación importante del ALME es que el número de componentes puros de una imagen no debe superar al número de bandas más uno utilizado para el cálculo de las fracciones. Esto se explica por los requerimientos del método matemático para solucionar el problema, que luego veremos.

Para obtener las reflectividades características de los miembros puros de la imagen pueden abordarse varios procedimientos que podemos dividir en dos grupos, según se utilicen los datos de la propia imagen o información externa. En el primer caso, podemos seleccionar los píxeles representativos de cada componente puro ($\rho_{m,k}$ en la fórmula anterior) a partir de varios criterios:

1. El más sencillo, sin duda, es seleccionarlo a partir del conocimiento del área de estudio (se entiende que de las condiciones del área en el momento de la adquisición de la imagen). Esto implica que la selección se realice con gran cuidado, ya que si introducimos como valores característicos de un componente puro valores extraídos de un píxel con mezcla, los resultados del ALME serán poco atinados. En caso de trabajar con imágenes de baja resolución espacial (como el AVHRR), localizar áreas homogéneas resulta muy complicado. Como precisamente sobre estas imágenes resulta de notable interés la aplicación de esta técnica —ya que facilita información sub-píxel que enriquece mucho las posibilidades temáticas de este sensor— se ha propuesto en varios estudios extraer los componentes puros a partir de imágenes de alta resolución, como SPOT o TM, previamente registradas y calibradas con las AVHRR. A partir de ellas se generan los valores característicos de cada componente puro, mediante técnicas de regresión o degradando artificialmente las imágenes de alta resolución hasta obtener el tamaño del píxel AVHRR (Caetano *et al.*, 1994; Foody y Cox, 1994; Hlavka y Spanner, 1995; Holben y Shimabukuro, 1993; Kerdiles y Grondona, 1995; Quarmby *et al.*, 1992).
2. Otros autores recomiendan extraer los datos de la imagen con un procedimiento más objetivo, que permita asegurar la calidad de las estadísticas aún con un escaso conocimiento del territorio. Entre las técnicas propuestas, tal vez la más extendida es la denominada *Pixel Purity Index* (PPI: Boardman *et al.*, 1995). El método parte de representar la nube de puntos de una determinada imagen en un espacio n-dimensional, que se va reproyectando aleatoriamente. En cada iteración se anotan los píxeles extremos de esa nube, señalándose los más puros como aquellos que alcancen con mayor frecuencia la condición de extremos. Un ejemplo de este algoritmo puede analizarse en la figura 7.22, simplificando la representación para 2 bandas. Se van rotando aleatoriamente los ejes, y se anotan los píxeles extremos en cada rotación, señalando luego los más puntuados como los vértices del espacio que se va a desmezclar.

Finalmente, la alternativa para extraer los componentes puros sería utilizar espectros de laboratorio o los almacenados en las bibliotecas espectrales disponibles, práctica muy común en la exploración minera (Kruse *et al.*, 1993*a*). Esta opción permite controlar mejor la pureza de los valores de entrada, evitando efectos anómalos a la cubierta, como serían las condiciones topográficas o del sustrato, ya que los espectros se toman en condiciones muy controladas. Sin embargo, esta alternativa tiene otros inconvenientes, como asumir que las imágenes están adecuadamente calibradas y corregidas del efecto

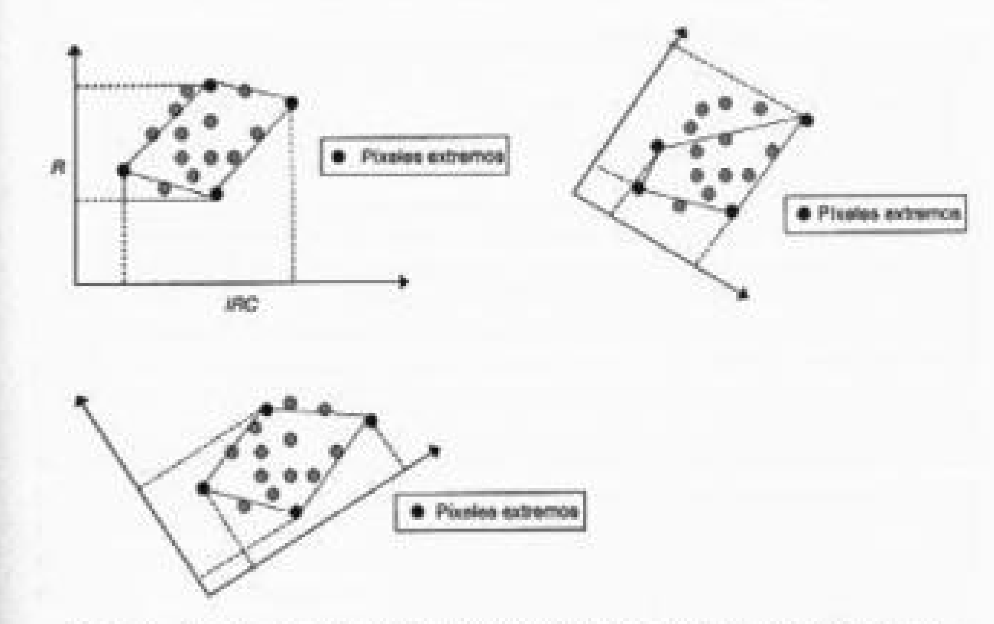


FIG. 7.22. *Fundamento del algoritmo PPI para buscar componentes puros de la imagen.*

atmosférico y topográfico, lo que, como ya hemos visto, no resulta trivial. Por esta razón, en buena parte de los estudios publicados, la delimitación de las radiancias características se realiza sobre la propia imagen, señalando en ella áreas puras, y suficientemente representativas, de las cubiertas que se vayan a «desmezclar».

Una vez obtenidas las reflectividades o ND característicos de cada componente puro pueden generarse las imágenes de las proporciones ($F_{i,j,m}$) solucionando para cada píxel la ecuación [7.23]. Normalmente, las proporciones se obtienen de tal forma que se minimice el error residual de cada píxel ($e_{i,j,k}$). Por ello, puede re-escribirse esa fórmula en función del error:

$$e_{i,j,k} = \rho_{i,j,k} - \Sigma_{m=1,p} F_{i,j,m} \, \rho_{m,k} \qquad [7.26]$$

de tal forma que los valores a estimar ($F_{i,j,m}$) permitan minimizar el error (o más concretamente, el cuadrado de los errores). Éste es el criterio denominado de ajuste por mínimos cuadrados, que tiene dos modalidades de solución: el ajuste con restricción y el ajuste ponderado (Shimabukuro y Smith, 1991). Precisamente, una de las ventajas del ALME frente a otras técnicas de interpretación es que nos ofrece una imagen de los errores del modelo en cada píxel, o dicho de otra forma, nos permite conocer el grado de ajuste de nuestro modelo a la realidad de las cubiertas presentes en cada píxel de la imagen. Lógicamente, si el error es alto para una determinada zona de la imagen se deduce que hay componentes puros de importancia que no se han considerado en el proceso.

Supongamos un ejemplo muy sencillo, como es el que aparece en la figura 7.23. Se parte de los ND de dos bandas (B1 y B2) y se pretende deducir las proporciones, para cada píxel, de dos miembros puros (c_1 y c_2), definidos por unos ND puros en las dos ban-

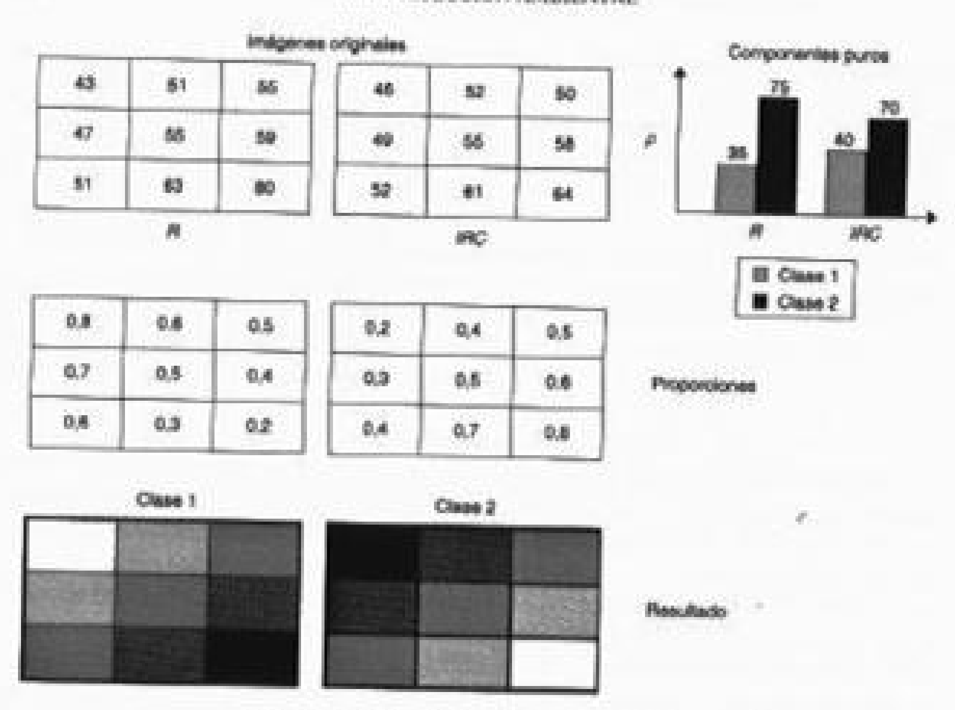


FIG. 7.23. *Ejemplo de aplicación del ALME.*

das (35 y 40, respectivamente, para la clase 1, y 75 y 70 para la clase 2). Con esos datos deberían generarse dos imágenes de proporciones, una correspondiente a c_1 y otra a c_2. Para ello, suponiendo en el ejemplo que no existe error (esto es que las estimaciones son perfectas en cada píxel) es preciso solucionar un sencillo sistema de ecuaciones con dos incógnitas. Por ejemplo, para el primer píxel (superior, izquierda) tendríamos:

$$43 = 30\,F_1 + 75\,F_2$$

$$46 = 40\,F_1 + 70\,F_2$$

esto es, el ND observado para ese píxel en las dos bandas (43, 46) se asume que está formado por una combinación lineal de las categorías puras c_1 y c_2, definidas por sus ND característicos en esas dos bandas. Para conocer la proporción de cada clase presente en ese píxel basta despejar en cada una de las ecuaciones F_2 para obtener F_1:

$$(43\text{-}35\,F_1)\,/\,75 = (46 - 40\,F_1)\,/\,70$$

de donde se deduce que $F_1 = 0{,}8$ y, en consecuencia, que $F_2 = 0{,}2$. De igual forma se procede con el resto de los píxeles de esta imagen, obteniéndose la matriz de proporciones resultante (figura 7.23). En este caso, asumiendo que no hay error residual en la estimación de las proporciones, bastaría en realidad con una sola ecuación, ya que, si se cumplen las restricciones de no-negatividad y exhaustividad que requiere el ALME,

entonces F_2 puede despejarse a partir de F_1 ($F_2 = 1 - F_1$). En suma, podríamos obtener el valor de F_1 a partir de una sola banda:

$$43 = 35\,F_1 + 75\,(1 - F_1)$$

Como es necesario contar con tantas ecuaciones como incógnitas, podemos seleccionar hasta un máximo de tantos componentes puros como bandas haya disponibles. Sin embargo, si añadimos el requisito de exhaustividad (la suma de las proporciones es igual 1), estamos incluyendo una ecuación adicional en el problema; de ahí que pueda incluirse hasta un máximo de $m + 1$ componentes, siendo m el número de bandas. Esto siempre que supongamos nulo el error, de otra forma, se incluye una incógnita más, y habría que limitar el número de componentes al de bandas.

El método para solucionar esos sistemas de ecuaciones es más complejo, lógicamente, al incluido en nuestro ejemplo. En consecuencia, es preciso abordar criterios más refinados para solucionar el sistema de ecuaciones planteado anteriormente. Entre los diversos procedimientos que se han propuesto para ello, el estimador más sencillo es el ajuste por mínimos cuadrados sin restricciones. En notación matricial, este estimador se expresa como (Gong *et al.*, 1994; Settle y Drake, 1993):

$$\hat{f} = (M^T M)^{-1}\, M^T\, X \qquad [7.27]$$

donde f indica el vector con las proporciones calculadas para cada píxel, M indica la matriz con los valores de los componentes puros en las bandas de análisis y X el vector con los valores del píxel en cuestión para esas mismas bandas. El superíndice T indica la transpuesta de la matriz y -1 la inversa. Este algoritmo es relativamente rápido, pero no satisface las restricciones antes mencionadas. Para solucionar esto basta con poner a cero los valores negativos de f y escalar el resto para que sumen 1. Otros criterios de solución que incluyen directamente estas restricciones pueden consultarse en Settle y Drake (1993) y Shimabukuro y Smith (1991). Mather (1998) apunta la importancia de que las bandas de entrada no están altamente correlacionadas; de lo contrario habrá serios problemas para invertir la matriz de entrada. Finalmente, también se han propuesto soluciones menos supervisadas, en donde los valores de los componentes puros no se conocen, lo que implica aumentar el número de incógnitas y acudir a soluciones no lineales, que se resuelven iterativamente analizando en cada paso la variación del error (Tompkins *et al.*, 1997).

El ALME resulta de gran interés para extraer información compleja de las imágenes hiperespectrales, pero no se restringe a este tipo de datos, sino que se ha empleado en contextos muy variados. Es muy apropiada para expresar el carácter continuo de los datos ambientales, que no tienen una clara solución de continuidad en el espacio. Además implica una interesante alternativa para extraer información de los sensores de baja resolución espacial, AVHRR, MODIS o Vegetation, ya que facilita estimaciones sobre las mezclas, tan abundantes en estos píxeles de gran tamaño, manteniendo una alta frecuencia de adquisición y bajo coste. El campo más claro de aplicación es el agrícola: superficie cultivada y rendimiento, en donde el ALME ha mostrado ya excelentes resultados (Kerdiles y Grondona, 1995; Quarmby *et al.*, 1992). Asimismo, resulta un aliado clave en los estudios de deforestación (Adams *et al.*, 1995; Holben y Shimabukuro, 1993; Shimabukuro *et al.*, 1994) para estudiar regeneración de especies vegetales (Hlavka y

Spanner, 1995), densidad de cabida cubierta (Gong *et al.*, 1994), cartografía de la vegetación (Roberts *et al.*, 1998), y en el seguimiento y discriminación de áreas quemadas (Caetano *et al.*, 1996; Martín y Chuvieco, 1998; Riaño *et al.*, 2001*b*). Además, se ha utilizado profusamente en cartografía de suelos y formaciones minerales (Adams *et al.*, 1986; Palacios-Orueta y Ustin, 1998; Smith *et al.*, 1990*a*; Smith *et al.*, 1990*b*).

Como ejemplo de esta transformación hemos calculado los componentes ALME de las categorías agua, vegetación y suelo descubierto para la imagen Torrel00. Para ello hemos utilizado un programa incluido en el paquete XPACE de PCI, que incorpora un algoritmo de mínimos cuadrados con restricciones de no negatividad y exhaustividad. Los componentes calculados se incluyen en la figura 7.24, que recoge también el término de error (RMS).

El comentario de estas imágenes de proporciones resulta bastante análogo al que hemos realizado de los componentes principales y *tasseled cap*, ya que están reflejando las tres dimensiones básicas de información incluidas en una imagen ETM. En este caso, cada componente tiene un sentido físico: la proporción de agua, vegetación o suelo que presenta, en un continuo desde la máxima cantidad (100 %) que aparece en las zonas espectralmente más similares al componente puro, hasta las que ofrecen una proporción prácticamente despreciable. El componente de agua presenta los valores más altos en los embalses del área de estudio, así como en algunos sectores de vegetación perennifolia, que muestran una afinidad intermedia entre el agua y la vegetación herbácea vigorosa (donde se definió el componente vegetación). Precisamente estas zonas de pastizal son las más claramente recogidas en el componente vegetación, así como los cultivos herbáceos de secano, mostrando valores medios las especies esclerófilas, principalmente el matorral y pinar. El suelo por su parte muestra valores más altos para las parcelas con poca o nula vegetación, así como los bordes de los embalses, cuyos márgenes estaban secos en esta época del año. Este componente es más abundante en el valle del Jarama, en el sector oriental de la imagen, donde es más frecuente la ocupación agrícola del territorio. Finalmente, el componente de error muestra un patrón bastante aceptable, con tendencia a valores bajos en toda la imagen, excepción hecha del área de pinar, en el vértice NW, que ofrece valores más elevados. Esto implica claramente que faltó este tipo de componente (podríamos haberlo denominado vegetación perennifolia, por ejemplo) en la definición de los componentes puros ALME, lo que hubiera facilitado una delimitación más clara de este sustrato espectral.

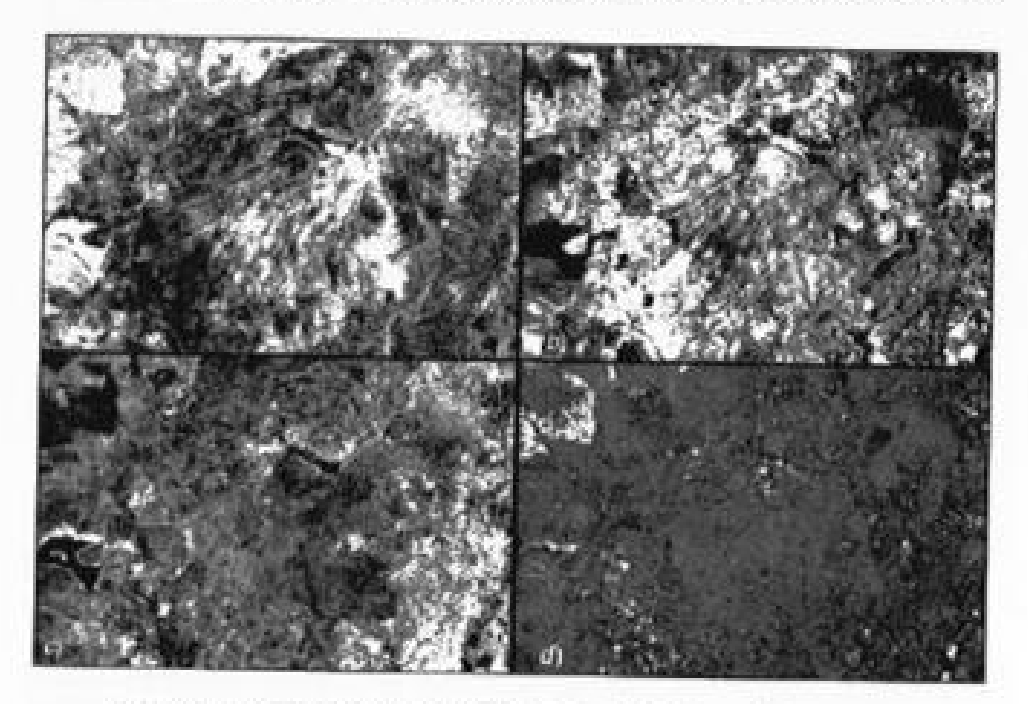


FIG. 7.24. *Componentes ALME de la imagen Torrel00: a) agua; b) vegetación; c) suelo; d) RMS.*

La figura 7.25 recoge otro ejemplo de aplicación de esta técnica, en este caso a la delimitación de los espacios verdes en una zona urbana. El objetivo último de este trabajo era extraer una serie de variables de la imagen para plantear modelos de calidad de vida urbana, tomando como ejemplo la ciudad de Maracaibo en Venezuela (Molina, 1998). El ALME se empleó en este contexto para extraer las proporciones de áreas ajardinadas dentro de la ciudad, ya que se consideró que sería una variable de interés para diferenciar sectores de calidad ambiental dentro de la ciudad. La ventaja del ALME en esta aplicación es permitirnos obtener una imagen más precisa de la distribución de jardines de pequeñas dimensiones. En una clasificación convencional, únicamente se clasificarían como áreas verdes los jardines de cierto tamaño (varias veces superior al tamaño del píxel), quedando infravaloradas las masas vegetales que se presentan en las urbanizaciones de mayor calidad residencial, que no suelen ocupar grandes extensiones, o al menos no de forma homogénea, ya que estarán imbricadas con superficies construidas. Para este análisis planteamos un componente ALME relacionado con los materiales de construcción, otro con la vegetación fotosintética (éstos serían los jardines), un tercero con la vegetación seca (la que no recibe un aporte de riego en verano, y por tanto se relaciona más con la vegetación residual urbana), y finalmente el margen de error. La distribución del componente vegetación (fig. 7.25*b*) permitió obtener una imagen mucho más realista de la distribución de los espacios verdes.

Otra aplicación de interés de esta técnica ha sido la discriminación de áreas quemadas utilizando principalmente sensores de baja resolución espacial, como el AVHRR (Caetano *et al.*, 1996, Martín, 1998). El problema que se plantea con el AVHRR es que sólo cuenta con 2 canales en el espectro óptico, por lo que sólo pueden deducirse 3 componentes (o con mas rigor dos), lo que dificulta la discriminación del área quemada con otras cubiertas de similares características espectrales como el agua y las sombras. En la figura 7.26 se comparan una imagen original AVHRR y el componente quemado de una transformación ALME (Martín y Chuvieco, 1998). Como puede observarse a simple vista, la caracterización de los grandes incendios es bastante atinada, acogiendo el componente ALME valores bastante altos para estas áreas quemadas.

El último ejemplo que recogemos en este epígrafe está extraído de una investigación sobre empleo de imágenes de satélite en el análisis de procesos de desertificación (Collado, 1998). Hemos seleccionado la comparación temporal entre los componentes ALME correspondientes a láminas de arena para dos fechas separadas 10 años en un sector de la provincia de San Luis (Argentina) especialmente afectado por este fenó-

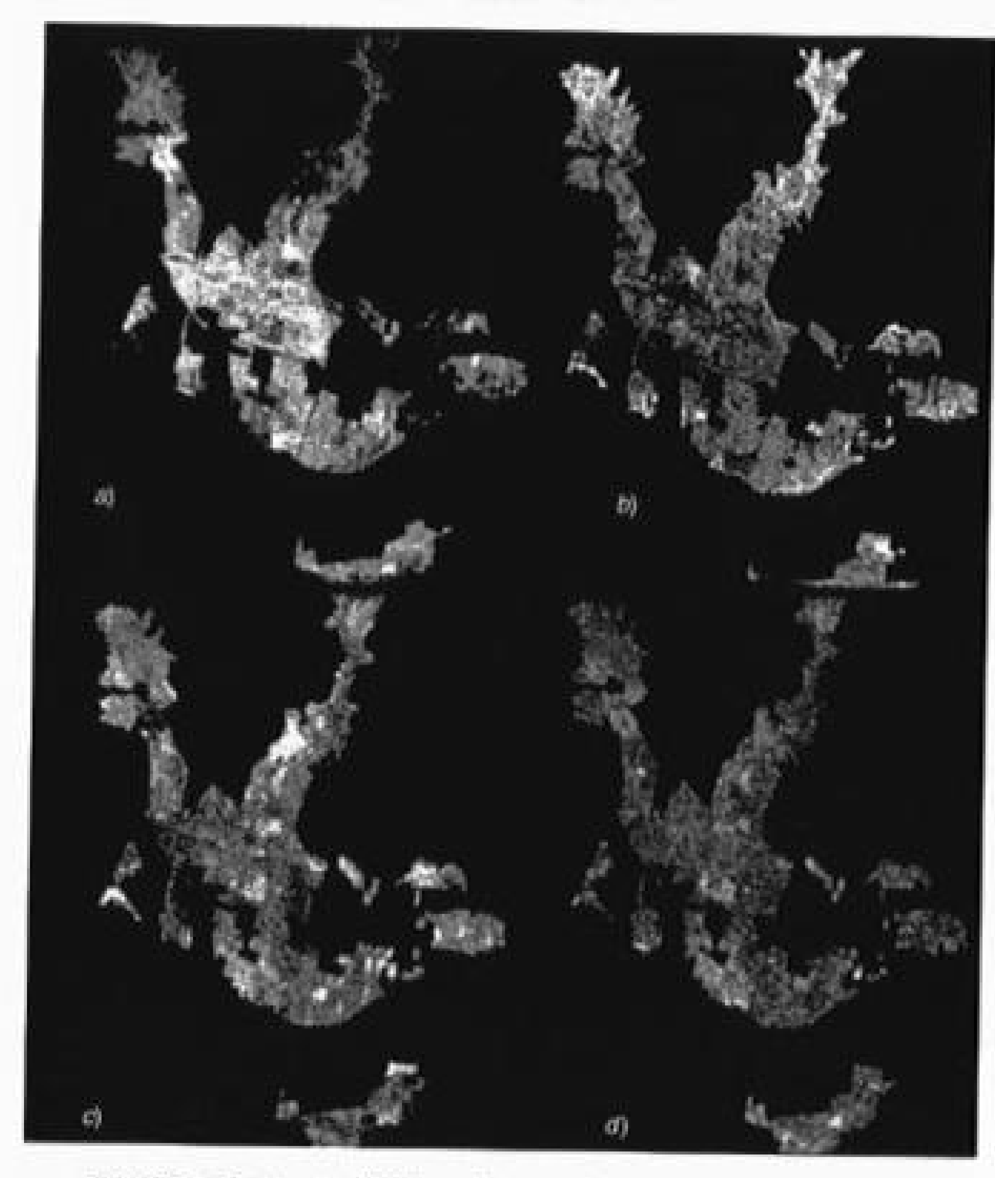


FIG. 7.25. *Componentes ALME para el sector urbano de Maracaibo (Venezuela): a) materiales de construcción; b) vegetación fotosintética; c) vegetación seca; d) RMS.*

meno. Puede observarse en la figura 7.27 cómo el ALME ha permitido discriminar con bastante detalle el área cubierta por arena, y nos permite seguir la evolución de este fenómeno una vez que las dos imágenes están registradas entre sí. Una simple resta en los ND de las dos imágenes nos ofrece un análisis de tendencia muy interesante, ya que la dirección de avance de los frentes dunares está en clara relación con los patrones de vientos dominantes en la región.

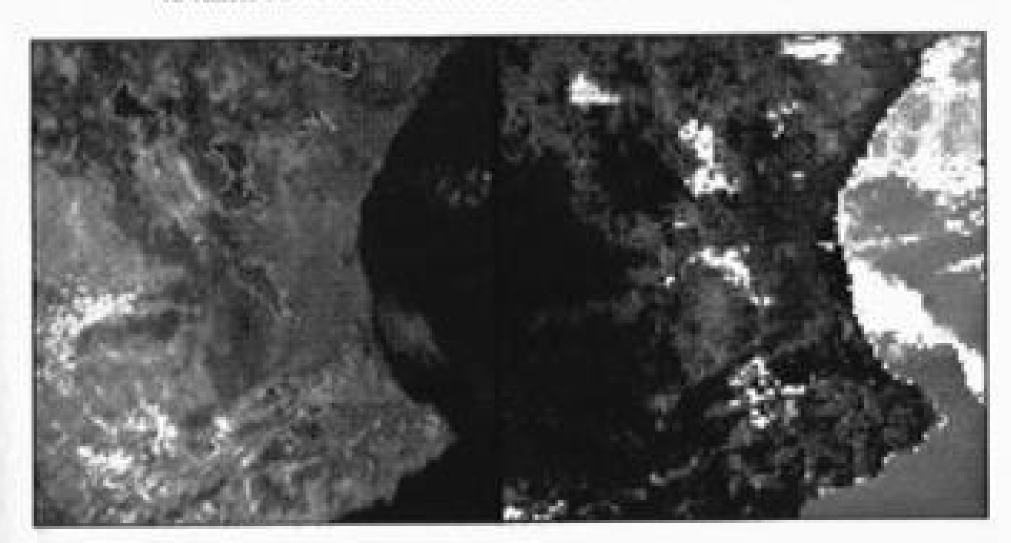


FIG. 7.26. *Componentes ALME de áreas quemadas. Imagen AVHRR correspondiente al litoral mediterráneo peninsular. A la derecha la imagen original con los perímetros de las áreas quemadas superpuestos; a la izquierda, componente quemado ALME.* (Martín, 1998.)

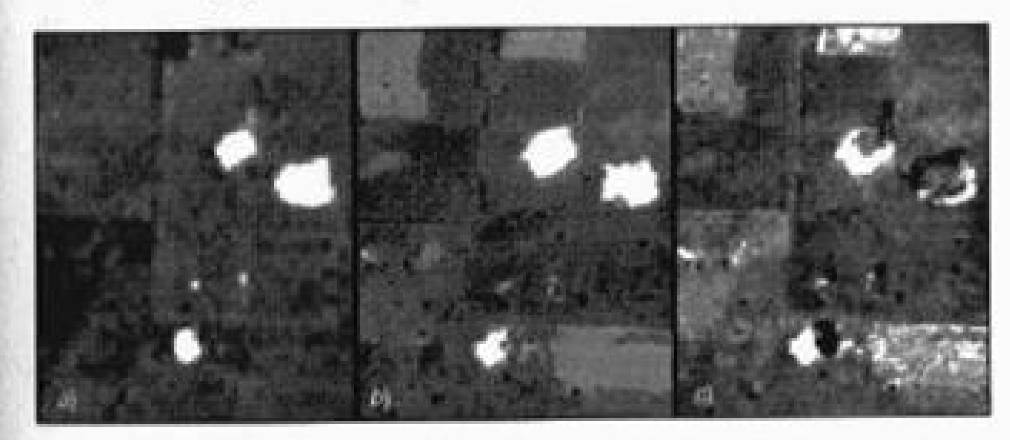


FIG. 7.27. *Componentes ALME de láminas de arena: a) 1982; b) 1992; c) resta de ambas.* (Collado, 1998.)

1.7. TÉCNICAS DE FUSIÓN DE DATOS

1.7.1. *Enfoques en la fusión de imágenes*

Resulta patente el interés de abordar estudios de teledetección a distintas escalas y con distintos niveles de detalle para entender mejor los procesos que afectan al conjunto del planeta. Gracias a los distintos grados de resolución actualmente disponibles podemos abordar mediante imágenes de satélite un rango muy amplio de escalas: desde la local —en condiciones muy controladas, pero de escasa representatividad espa-

cial— hasta el global, potencialmente menos fiable pero con mayor capacidad de generalización (Ehleringer y Field, 1993; Quattrochi y Goodchild, 1997).

Como es lógico, no existe ningún sensor que pueda facilitar ambos niveles de detalle simultáneamente, acercándose más a una escala local o global según las características de su diseño. El interés de poder abordar estudios a distintas escalas hace que las técnicas de integración de datos provenientes de distintos sensores se consideren cada vez con mayor atención, dando lugar a toda una nueva línea de trabajo en teledetección que recibe el nombre genérico de fusión de datos, que incluye asimismo la integración entre las imágenes de satélite y otras variables espaciales (Gong, 1994; Wald, 1999).

El objetivo último de estas técnicas es aprovechar las ventajas particulares de los datos que se ponen en relación, paliando sus defectos; por ejemplo, podrían combinarse imágenes de distintas resoluciones espaciales, temporales o que abarquen distintas bandas del espectro (radar-óptico). Éste sería el caso de generar una imagen sintética a partir de una pancromática de alta resolución espacial con una multiespectral con píxel más grosero: obtendríamos la calidad espacial de la primera con el contraste cromático de la segunda. De igual forma, podríamos integrar imágenes de satélite con mapas de temperaturas, MDE, o series de vegetación, en una clasificación integrada, de cara a mejorar la discriminación de un determinado rasgo de interés.

En pocas palabras, lo que se pretende es mejorar la calidad de los datos, ya sea en lo que se refiere a su aspecto visual, ya a la discriminación digital de ciertas categorías, ya a mejorar la fiabilidad de la estimación de una determinada variable, o ya a demostrar la solidez de un determinado método de análisis.

La fusión de datos puede plantearse a distintos niveles. El más intenso llevaría a generar imágenes sintéticas, combinando información procedente dos o más sensores para producir una sola imagen resultado; el segundo implicaría tratar información de varias fuentes en paralelo, de cara a mejorar la discriminación de un cierto rasgo de interés; similar a él también podríamos plantear la integración de los resultados obtenidos de varias fuentes independientes; finalmente, puede proponerse integrar varias versiones de los datos (imágenes sintéticas y originales, resultados de la interpretación) al nivel de la toma de decisiones (Gong, 1994).

1.7.2. *Obtención de imágenes híbridas*

De los objetivos arriba comentados, sin duda el más habitual en las técnicas de fusión de datos ha sido el que tiende a realzar el aspecto visual de una determinada imagen con información proporcionada por otra de mejor resolución espacial. Al final del proceso tendríamos una imagen sintética (multirresolución), que alberga el detalle cromático de unas bandas sobre la calidad espacial de otra.

La llegada de los sensores de muy alta resolución espacial (Ikonos, Quickbird, IRS-1C, Kompsat) ha renovado el interés de esta aplicación, ya que permite mejorar considerablemente la definición de una determinada imagen, de cara a su posterior análisis visual o integración con otros datos espaciales en el entorno de un SIG. Sin embargo, las primeras ideas para obtener este tipo de productos se remontan a los años ochenta, cuando se propusieron las primeras técnicas para fundir imágenes Landsat-MSS y RBV (Short, 1982), o incluso Landsat y fotografías aéreas digitalizadas (Iverson *et al.*, 1989). Con el lanzamiento del SPOT en 1986 se comenzaron a producir imágenes sinté-

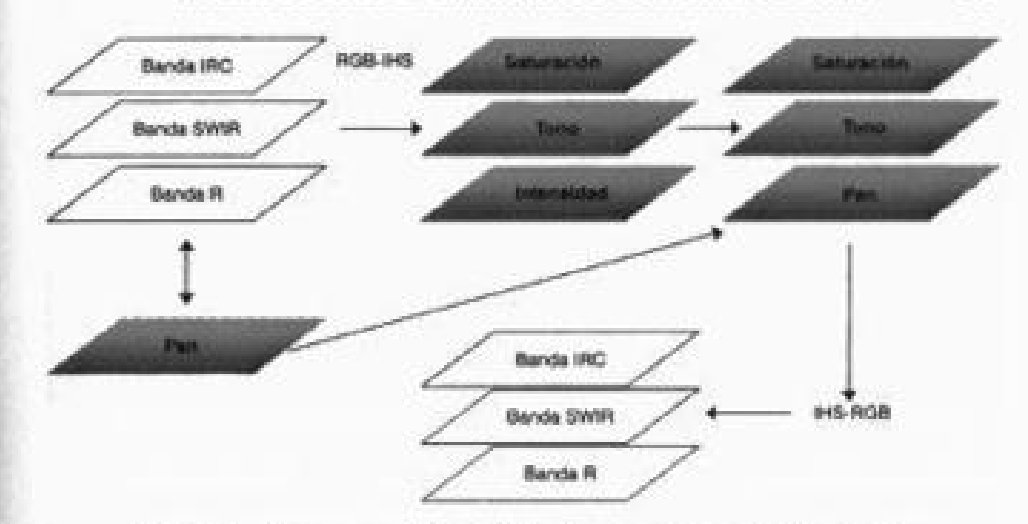


FIG. 7.28. *Esquema para la fusión de imágenes mediante el algoritmo IHS.*

ticas entre sus canales pancromático (10 m) y multiespectral (20 m) (Carper *et al.*, 1990), o incluso entre el SPOT pancromático y el multiespectral Landsat-TM (30 m). Actualmente, el mercado de los productos híbridos se centra sobre todo en combinar las imágenes de sensores de muy alta resolución (como el Ikonos pancromático, con 1 m), con los productos multiespectrales de ese mismo sensor (4 m), de cara a la cartografía catastral de detalle. No obstante, para aplicaciones de escalas medias, la fusión del canal pancromático del sensor ETM+ (15 m) con los multiespectrales (30 m) también puede resultar de gran interés. La creciente disponibilidad de sensores hiperespectrales también permite ampliar este objetivo hacia fusiones de distinta naturaleza según el objetivo último de la interpretación (Robinson *et al.*, 2000).

Se han propuesto varias técnicas para obtener imágenes híbridas de dos resoluciones espaciales distintas (Tapiador y Casanova, 2001). La más empleada, hasta el momento, ha sido la transformación IHS, que vimos anteriormente, por lo que nos centraremos aquí principalmente en ella. Este proceso de fusión se ilustra en la figura 7.28.

Esta fusión parte de realizar una composición en color correspondiente a la imagen multiespectral de peor resolución que se pretende realzar con otra pancromática. Como es lógico, esta última debería incluir condiciones de observación similares a la primera, siendo lo más recomendable que se tomen simultáneamente, como ocurre con el sensor ETM+ o la cámara del Ikonos. El primer paso en la fusión de dos imágenes es asegurar que tengan el mismo tamaño de píxel y se refieran a la misma posición en el espacio. Esto implica una previa georreferenciación de esas dos imágenes, o al menos un ajuste relativo entre ellas. En ese paso, el píxel de la imagen multiespectral debe ampliarse hasta el tamaño del píxel de la pancromática (reduplicando el valor de sus ND), lo que garantizará que puedan superponerse adecuadamente.

A continuación se aplica una transformación de coordenadas RVA a IHS, tal y como vimos previamente (1.5). Puesto que el tono y la saturación refieren al contenido espectral de la imagen, mientras la intensidad se relaciona con las variaciones espaciales del albedo, que están más en relación con las características espaciales de la ima-

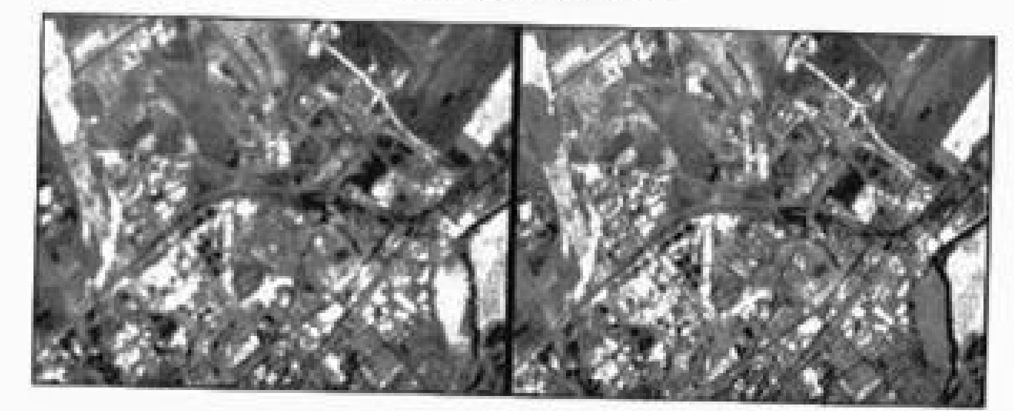


FIG. 7.29. *Imagen de intensidad de una composición ETM 4/5/3 (dcha.) y del canal pancromático (izqda.) de la imagen Alcalá99.*

gen, este componente tenderá a presentar una buena correlación con la imagen pancromática (fig. 7.29). En consecuencia, podemos sustituir una por otra, de tal forma que se incorpore el detalle espacial de la pancromática sin afectar a la tonalidad de la composición en color original. Por último, se aplica la transformación inversa, de componentes IHS a RVA, obteniéndose un producto visual muy mejorado (fig. 15*).

Este proceso resulta adecuado en muchas aplicaciones, pero puede ofrecer pobres resultados si el rango espectral de la pancromática no se ajusta bien al correspondiente a las tres bandas que se mezclan en la composición RVA. De hecho, se comprobó hace unos años que el componente Intensidad de una composición SPOT no estaba bien correlacionado con el pancromático (Chavez *et al.*, 1991; Pellemans *et al.*, 1993). En consecuencia, se ha propuesto otras técnicas alternativas para la obtención de imágenes híbridas, como serían las siguientes:

1. Una integración ponderada entre el canal pancromático y el canal infrarrojo cercano:

$$M_p = \frac{2\,\text{Pan} + ND_{IRC}}{3} \qquad [7.28]$$

el resultado se sustituye por el componente Intensidad (Chavez *et al.*, 1991).

2. Una suma ponderada del pancromático con los canales multiespectrales, aplicando previamente un filtro de paso alto para realzar el componente espacial de la imagen pancromática (Chavez *et al.*, 1991).

3. Una sustitución selectiva del pancromático por las bandas espectrales verde y roja, tras aplicarle unas correcciones radiométricas para reducir las diferencias de calibración entre bandas (Pellemans *et al.*, 1993).

4. Una regresión multibanda para las bandas que tienen poca correlación con la pancromática. Esta regresión incluye la banda pancromática y las otras multiespectrales que intervienen en la composición en color (Munechika *et al.*, 1993).

Más recientemente se han propuesto métodos provenientes del mundo de la cartografía, que subrayan la diferente importancia de las variables visuales en la representación de imágenes. Éste es el caso de un método propuesto por el Centro Canadiense de Teledetección que permite integrar imágenes radar, modelos digitales de elevación e imágenes ópticas, utilizando una variante del método IHS para reforzar la visualización de rasgos tridimensionales (Toutin *et al.*, 1998).

También son recientes las aplicaciones de la transformación de «onditas» (*Wavelets*) en el dominio de las frecuencias, para obtener imágenes híbridas con dos resoluciones distintas (Garguet-Duport, 1997; Yocky, 1996), y el empleo de técnicas estadísticas para maximizar la información extraíble de las imágenes utilizando el concepto de entropía (Tapiador y Casanova, 2001).

1.7.3. *Interpretación sintética con datos de distintas fuentes*

Una forma concreta de combinar información, que se ha venido aplicando casi desde el inicio de la teledetección digital, es la clasificación conjunta de datos de distintas fuentes, incluyendo no sólo imágenes de varios sensores, sino también otras variables geográficas, como pueden ser mapas de precipitación, temperatura o suelos. El desarrollo de los SIG a lo largo de los años ochenta y noventa ha reforzado esta tendencia, que luego tendremos ocasión de comentar con más detalle (cap. 9). Dejaremos para este epígrafe aquellos aspectos de la relación entre ADI y SIG que conciernen más a la integración propiamente dicha.

Utilizar datos procedentes de distintas fuentes es una alternativa interesante para mejorar la discriminación de ciertas cubiertas de interés, que pueden ser difícilmente discriminables si nos basamos exclusivamente en los datos de la imagen. Por ejemplo, para diferenciar olivar y viñedo puede ser necesario acudir a mapas de suelos para estimar la señal mixta que proporcionan, ya que esta mezcla resulta clave en la señal detectada por el sensor. En un inventario forestal, la situación topográfica (proporcionada por un MDE) o la textura (extraída de una imagen radar) puede ser crucial para distinguir distintas especies, difícilmente diferenciables de otra forma.

Naturalmente, esta integración plantea también distintos problemas, ya que se pretende analizar en conjunto datos que provienen de diversos orígenes y, por tanto, pueden ofrecer distintos niveles de detalle y escalas de medida. Como veremos en el siguiente epígrafe, la mayor parte de los métodos de clasificación digital se basan en técnicas estadísticas que no pueden aplicarse a variables categóricas, donde los individuos se diferencian sólo por pertenecer a categorías distintas sin relación numérica entre ellas (como ocurre, por ejemplo, mapas de suelos o de vegetación). En consecuencia, si quieren emplearse estas variables en la clasificación digital es necesario emplear otro tipo de técnicas, como pueden ser los clasificadores basados en criterios de decisión o en redes neuronales que luego comentaremos (2.3.4). El análisis de errores también se modifica notablemente cuando se plantean trabajos integrando varias fuentes, ya que cada una contará con sus propios problemas e incertidumbres (Gong, 1994).

No obstante, el recurso a contar con información de diversas fuentes ha sido frecuente en el ADI. Esta integración puede realizarse con varios objetivos (Hutchinson, 1982):

1. Para estratificar la imagen, previamente a la clasificación, de acuerdo a rasgos fisiográficos homogéneos. Esto permite reducir la varianza espectral de las distintas categorías que pretenden discriminarse (Núñez *et al.*, 1983).
2. Para introducir nuevas variables en la clasificación, combinando las bandas originales, con MDE o cartografía convencional digitizada (Benediktsson *et al.*, 1990; Pons y Solé-Sugrañes, 1994; Riaño *et al.*, 2001*a*; Salas y Chuvieco, 1995).
3. Para re-clasificar algunas categorías en caso de que no hayan sido discriminadas correctamente a partir de información espectral (Hutchinson, 1982; Richards y Xia, 1999; Skidmore, 1989).

Entre los trabajos pioneros en esta integración de datos se encuentra el método para la realización de inventarios forestales que desarrollaron varios profesores de la Universidad de California, Santa Barbara (Franklin *et al.*, 1986). Este método, aplicado a varios bosques de California, combinaba el tratamiento digital de imágenes Landsat con MDE e información de campo. A partir de las imágenes se elaboraron algunos índices de textura, incorporados a la clasificación junto a las bandas originales. Asimismo, se empleó un MDE para obtener la altitud, pendiente y orientación, lo que permitió refinar notablemente la discriminación, tanto de especies, como de densidades y alturas. Trabajos similares se han desarrollado por otros autores en el inventario forestal (Miller y Williams, 1978; Wu, 1980), y en la cartografía de modelos combustibles (Castro y Chuvieco, 1998; Riaño *et al.*, 2001*a*; Salas y Chuvieco, 1995; fig. 7.30). Estos enfoques integrados permiten abordar clasificaciones mucho más ricas, ya que se combinan criterios espectrales (propiedades ópticas de las especies), espaciales (estructura, situación) y temporales (dinámica atmosférica, variedad fenológica, productividad), ofreciendo una evaluación más completa del territorio en estudio.

En los últimos años se han propuesto nuevas técnicas para integrar imágenes con información procedente de varias fuentes. Entre ellas, puede destacarse la teoría de la evidencia, propuesta hace algunos años por Shafer y Dempster como una extensión de la doctrina bayesiana de la inferencia estadística. Esta técnica permite trabajar tanto con variables cualitativas como cuantitativas (Richards y Xia, 1999, cap. 12), asignando una serie de pesos, en las distintas variables, a las categorías que intervienen en la clasificación a partir de un cierto conocimiento de su certeza (Gong, 1996; Wang y Civco, 1994). Por ejemplo, pueden establecerse relaciones de distinta intensidad, según estemos más o menos seguros de su fiabilidad. Esos pesos se transforman en lo que se conocen como funciones de plausibilidad (*plausibility*) y de «creencia» (*belief function*: Srinivasan y Richards, 1990; Wilkinson y Mégier, 1990), que definen, respectivamente, la posibilidad de que una observación pertenezca a una cierta clase y la seguridad que tengamos de que lo sea. Por ejemplo, podemos afirmar que un píxel con un determinado valor de NDVI cuenta con una probabilidad de ser vegetación de 0,4 considerando los valores específicos de la vegetación (función de creencia), o también que tiene un rango de probabilidades de ser vegetación de 0,8 (función de plausibilidad) si se estima que la probabilidad de no ser vegetación es de 0,2. Estas estimaciones pueden generarse a partir de las probabilidades obtenidas en clasificadores estadísticos convencionales, o de otras fuentes más cualitativas, como el propio consejo de expertos. Richards y Ji (1999) indican

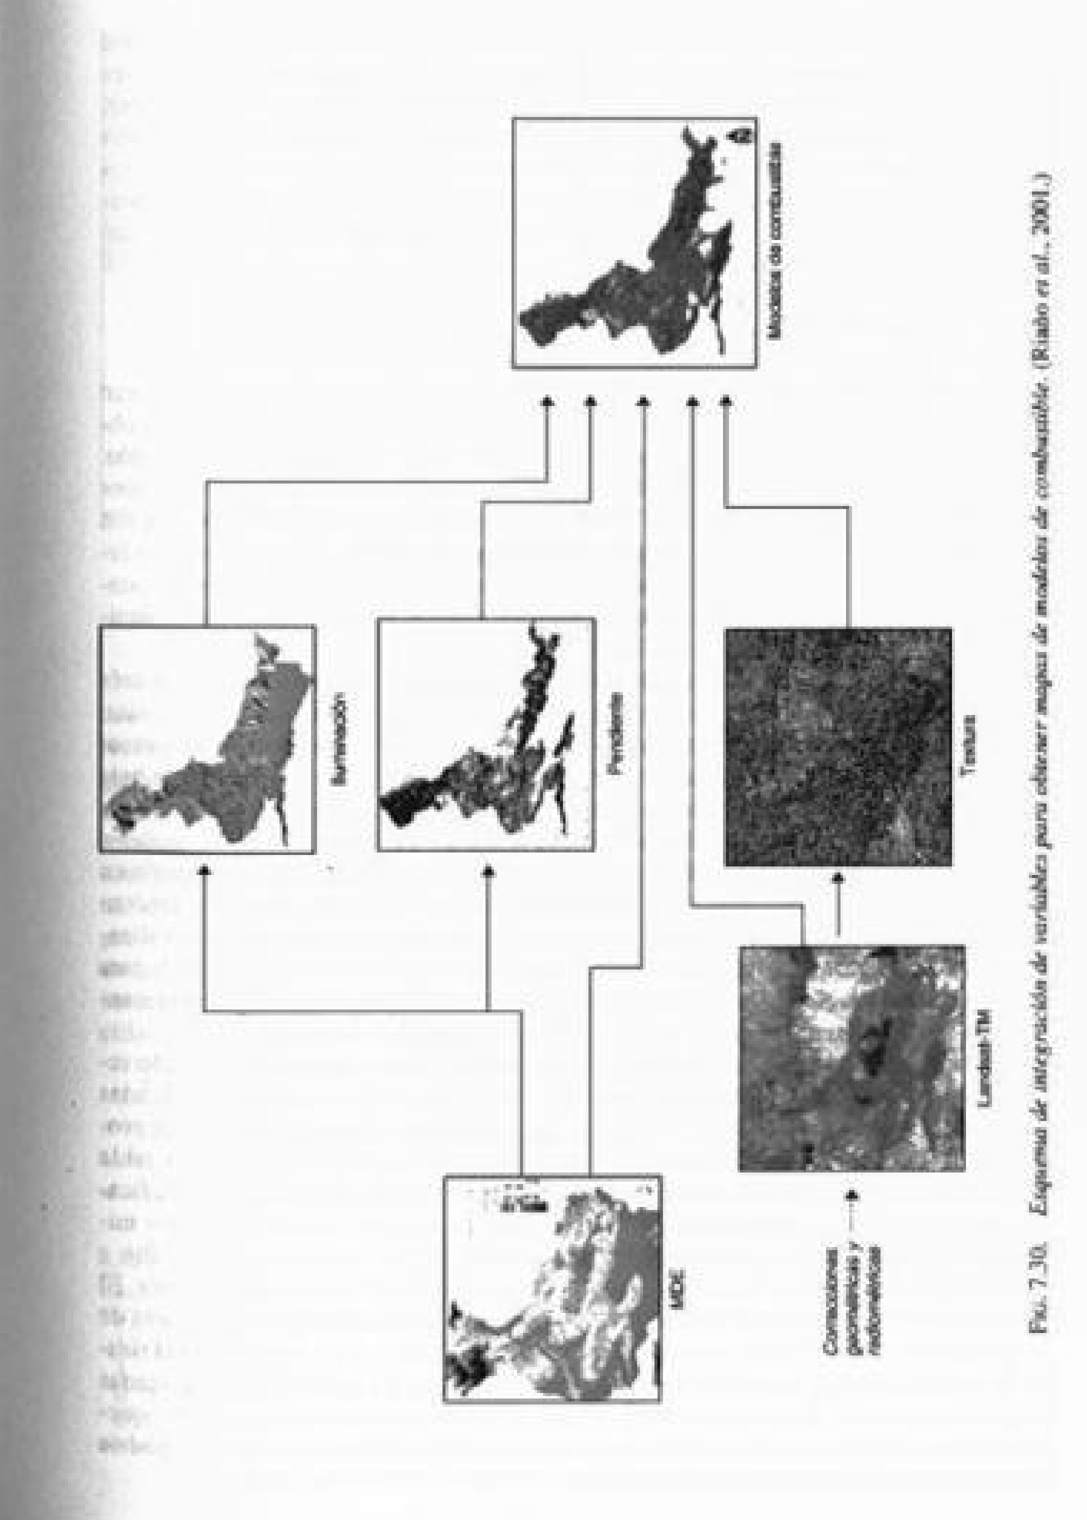


FIG. 7.30. *Esquema de integración de variables para obtener mapas de modelos de combustible.* (Riaño *et al.*, 2001.)

varios criterios para catalogar esas inferencias en distintas clases: definitivamente verdadera, muy probable que sea verdadera, posible que lo sea, posible que no lo sea y contradictoria. Siguiendo unas reglas de combinación, propuestas por Dempster, pueden combinarse las funciones de evidencia de distintas variables, facilitando una integración mucho más matizada entre fuentes que pueden tener un carácter muy variado. La comparación entre estos enfoques y otros estadísticos más clásicos ha permitido verificar las posibilidades de esta técnica, especialmente cuando se presentan clases mixtas (Lee *et al.*, 1987).

1.7.4. *Integración de resultados*

En este último apartado consideramos los procesos de integración que se refieren a los resultados del análisis, cuando se pretenda poner en relación dos documentos obtenidos a partir de la interpretación de imágenes de distintos sensores. Por ejemplo, podríamos comparar mapas de cobertura del suelo generados en dos períodos distintos a partir de datos MSS (años setenta) y TM (años noventa), o mapas de deforestación derivados a dos escalas distintas a partir de imágenes AVHRR y TM de la misma fecha. El primero sería un ejemplo de análisis multitemporal, que luego tendremos ocasión de comentar con más detalle, y el segundo de análisis espacial multisensor, similar al muestreo estadístico en varias fases.

Aquí nos centraremos en este segundo enfoque, ya que puede resultar de interés para poner en relación modelos de interpretación que se generan a distintas escalas. Algunos ejemplos de este planteamiento podrían ser utilizar una imagen de alta resolución espacial para extraer los componentes puros del ALME en una imagen de baja resolución, o para simular la señal de una determinada cubierta que obtendría un sensor de peor resolución, o para comparar los inventarios de superficies deforestadas a distintos niveles de detalle. En varios trabajos sobre estimaciones de deforestación en la Amazonía (Shimabukuro *et al.*, 1994; Skole y Tucker, 1993) se ha puesto en evidencia el interés de este tipo de trabajos, ya que permiten extrapolar estimaciones realizadas a partir de un cierto nivel de detalle (por ejemplo, desde imágenes TM o HRV para sectores con buen control de campo), al conjunto de un amplio territorio que se pretende inventariar (utilizando imágenes AVHRR o Vegetation).

Una forma sencilla de fusión de datos a este nivel que venimos comentando sería la integración entre resultados binarios, por ejemplo entre áreas clasificadas como quemadas/no quemadas a dos resoluciones distintas. La integración de un producto de síntesis entre las dos podría realizarse de varias maneras (fig. 7.31 y tabla 7.5). Por un lado, podríamos optar por retener únicamente lo que se haya identificado como quemado en las dos imágenes. Éste sería un enfoque conservador, que minimizaría los errores de comisión (detectar como incendio lo que no lo es), aun a costa de perder posibles incendios bien clasificados en una de las dos imágenes. El planteamiento opuesto sería retener lo que haya sido identificado por cualquiera de los dos: esto reduciría el número de incendios no detectados, pero aumentaría el riesgo de falsas alarmas. En ambos casos, cuando coincidan las superficies catalogadas por ambos sensores, habrá que decidir de cuál de las dos extraemos el perímetro quemado. Parece lógico hacerlo de la imagen de alta resolución, aunque también podría haber razones para elegir la otra imagen.

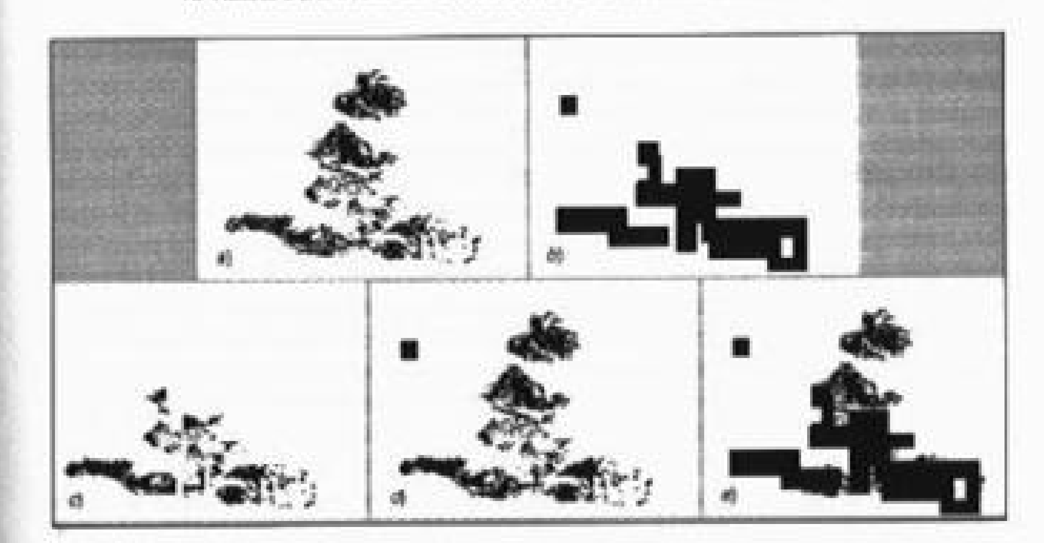


Fig. 7.31. *Esquema de integración entre resultados obtenidos a partir de dos sensores de alta a) y baja b) resolución; c) coincidencias entre los dos; d) unión entre ambas, pero prevalece la alta resolución; e) unión entre ambas, pero prevalece la baja resolución.*

Otros posibles cruces primarían una de las dos imágenes, considerando que, por cualquier razón, nos merece más crédito que la otra. Así, podríamos decidir que prevaleciera la de mayor resolución, en cuyo caso se retendrían únicamente las áreas catalogadas en esta imagen, si bien se retendrían también los píxeles de la de menor resolución cuando se puedan considerar pertenecientes a incendios detectados en la de alta resolución. Esto puede tener sentido si asumimos que la de alta puede haber detectado sólo la parte más intensamente quemada, pero no los bordes del incendio, que podrían haberse detectado mejor en la de baja resolución. Asimismo, podríamos plantear que prevaleciera la de baja resolución; esto es, se retendrían únicamente los incendios detectados en ella, si bien en aquellos que también se hayan discriminado en la de alta resolución se retendrían los píxeles de la de alta (si siempre eligiéramos los de baja, sencillamente no haríamos fusión).

Esto es un ejemplo de las posibilidades de integración entre imágenes de distintos

Tabla 7.5. *Esquema para la integración entre dos imágenes binarias de distinto sensor: alta resolución (A), baja resolución (B)*

Resolución		*Criterio de fusión*			
Alta	*Baja*	*Ambos prevalecen*	*Ninguno prevalece*	*Alta prevalece*	*Baja prevalece*
1	1	1 (A + B)*	1 (A)	1 (A)	1 (B)
1	0	1	0	1	0
0	1	1	0	0	1
0	0	0	0	0	0

* Se indica entre paréntesis la fuente del píxel resultante de la fusión.

sensores, que puede dar idea de las perspectivas futuras que plantea un análisis integrado de la información.

2. Categorización de imágenes: clasificación digital

2.1. Introducción

Todavía para la mayor parte de los usuarios de la teledetección la clasificación supone la fase culminante del ADI. Hacia ella se orientan buena parte de los realces y correcciones previamente analizados, así como algunas transformaciones.

Como fruto de la clasificación digital se obtiene una cartografía e inventario de las categorías objeto de estudio. La imagen multibanda se convierte en otra imagen, del mismo tamaño y características de las originales, con la importante diferencia de que el ND que define cada píxel no tiene relación con la radiancia detectada por el sensor, sino que se trata de una etiqueta que identifica la categoría asignada a ese píxel. A partir de una imagen como ésta puede fácilmente generarse cartografía temática, así como un inventario estadístico del número de píxeles —y por tanto de la superficie— asignados a cada categoría (fig. 7.32).

De acuerdo a Cihlar *et al.* (1998) un método de clasificación debería contar con las siguientes características: 1) exacto; 2) reproducible por otros, dadas las mismas variables de entrada; 3) robusto (no sensible a pequeños cambios en las condiciones de entrada, aunque permita explotar enteramente la información de esas variables); 4) exhaustivo, que cubra todo el territorio de estudio, y 5) objetivo, que no esté marcado por las decisiones del intérprete. A nuestro juicio, este último punto es matizable, ya que el conocimiento del intérprete puede resolver algunos problemas en la discriminación de cubiertas, si bien estamos de acuerdo en que obtener una buenos resultados en la clasificación no debe depender únicamente de que el intérprete sea más o menos experto en el área de estudio o en el manejo de los programas.

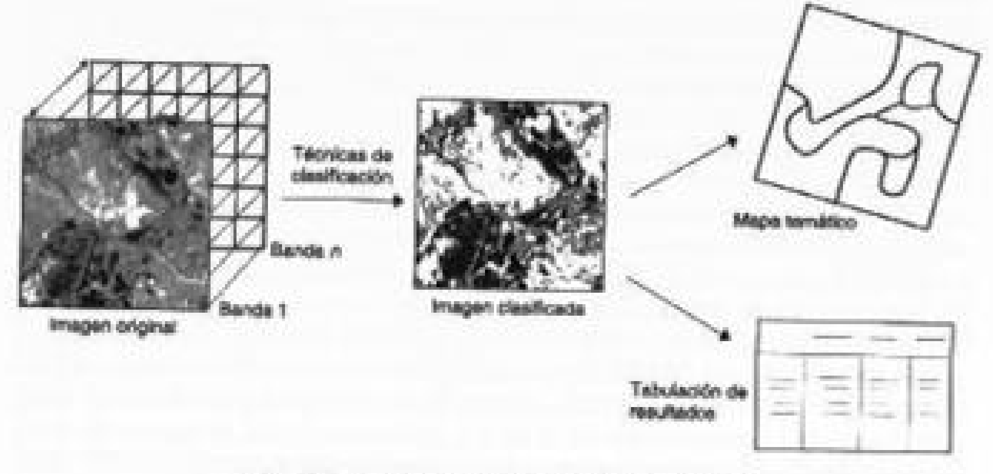


FIG. 7.32. *Fundamentos de la clasificación digital.*

La clasificación de la imagen se beneficia notablemente de algunos procesos de corrección y realce previamente estudiados. Sin embargo, conviene considerar que puede abordarse una clasificación exclusivamente a partir de los ND de la imagen, ya que las categorías temáticas suelen definirse de modo relativo a las condiciones específicas de la escena a clasificar. En otras palabras, en principio la clasificación digital no busca una definición absoluta de cada cubierta, que pudiera ser aplicable a cualquier imagen, sino más bien una caracterización relativa, válida para una determinada imagen y un territorio concreto (Robinove, 1981). Si adoptamos este planteamiento, no resulta preciso conocer detalladamente las condiciones de adquisición: basta identificar en la imagen las clases a discriminar, sin pretender que esa identificación sea extrapolable a otras situaciones. En resumen, en ese contexto no se trataría de establecer un modelo entre medidas digitales y parámetros físicos, sino entre medidas digitales, para un sensor, una zona y una fecha determinados, y tipos de cubierta. En este sentido, la clasificación supone un enfoque más cualitativo, si bien, por tratarse de un proceso numérico, incorpora un aparato estadístico ciertamente importante. Lógicamente, esto supone el nivel de interpretación más elemental, aunque todo lo dicho en este capítulo también es aplicable al trabajo con valores calibrados de radiancia, reflectividad o temperatura. De hecho, las tendencias más modernas en clasificación pretenden establecer leyes de validez general, aptas para una interpretación automática de la imagen, y eso necesariamente requeriría trabajar con variables físicas.

Como ya hemos indicado, la clasificación digital implica categorizar una imagen multibanda. En términos estadísticos, esto supone reducir la escala de medida, de una variable continua (los ND originalmente detectados por el sensor) a una escala categórica (tipos de vegetación) u ordinal (densidades de vegetación). La apariencia externa puede resultar muy similar entre la imagen original y la clasificada, ya que presentan el mismo tamaño y pueden visualizarse en niveles de gris. Sin embargo, es importante considerar que no pueden aplicarse ciertas operaciones estadísticas a una imagen clasificada, ya que, pese a ser digital, no está medida en una escala cuantitativa, sino generalmente cualitativa. Un sencillo ejemplo bastará para explicar este razonamiento. El objetivo de los filtros espaciales (ver 6.5.4) es asimilar o reforzar los contrastes en los ND de píxeles vecinos. Esto implica que el ND de un determinado píxel se obtiene mediante algún tipo de operación aritmética con los ND de los píxeles inmediatos, lo que implica una escala de medida continua. En una clasificación de tipos de cultivo, por ejemplo, no puede realizarse ninguna operación de este tipo, ya que la categoría 1 (p. ej., cebada) y la 2 (p. ej., trigo) no tienen relación numérica entre sí (1 no es mayor o menor que 2), y, en consecuencia, no tiene ningún sentido, entre otras cosas, promediarlas. Por tanto, en imágenes clasificadas las operaciones espaciales entre píxeles vecinos deben basarse en parámetros estadísticos apropiados para variables nominales (la moda o el índice de variación cualitativa).

El ND de un píxel clasificado, en definitiva, es el identificador de la clase en donde se haya incluido. Estas clases pueden describir distintos tipos de cubierta (variable nominal o categórica), o bien intervalos de una misma categoría de interés (variable ordinal). Una clasificación de especies vegetales estaría dentro del primer grupo, mientras un intento de señalar niveles de afectación en un incendio forestal o de humedad en el suelo, en el segundo.

Los primeros ensayos de clasificación digital de imágenes de satélite se basaron exclusivamente en los ND de la imagen (ya fueran originales o tras convertirlos a magnitudes físicas). Como ya sabemos, estos ND son una traducción digital de un flujo energético recibido por el sensor para una determinada banda del espectro. En consecuencia, una clasificación basada exclusivamente sobre ND puede denominarse propiamente clasificación espectral. Con ser muy rica esta información, no siempre es capaz de separar cubiertas, pues puede haber distintas categorías temáticas con un comportamiento espectral similar. En ese caso se recomienda acudir a las otras dos dimensiones de información que contiene una imagen: la espacial y la temporal. En el primer caso se trataría de incorporar a la clasificación la estructura o el contexto espacial en el que aparece cada píxel. En el segundo se aportarían datos sobre su evolución estacional, lo cual es especialmente crítico para la discriminación de cubiertas vegetales. Finalmente, puede ocurrir que ninguna de estas tres dimensiones sea suficiente para separar ciertas cubiertas, y sea preciso acudir a información auxiliar (topografía, suelos, etc.). A lo largo de este apartado veremos algunos procedimientos para abordar estos enfoques alternativos, si bien nos centraremos principalmente en la interpretación de los datos espectrales.

Simplificando las cosas, la clasificación digital de imágenes sigue cauces análogos a los que se emplean en foto-interpretación. En esta técnica, en primer lugar el intérprete identifica el patrón visual asociado a cada cubierta, de acuerdo a una serie de criterios: tono, textura, forma, contexto, disposición, etc., tal y como aparecen en unos fotogramas tipo. Posteriormente, delimita sobre el resto de las fotografías las zonas que se corresponden con ese modelo previamente definido. En otras palabras, asigna a cada categoría unas determinadas superficies, en función de la semejanza de éstas con el patrón-tipo identificado previamente. Por último, verifica sobre el terreno la interpretación realizada.

Éste es también el esquema de la clasificación digital. Basta traducir los criterios analógicos por digitales, por cuanto se realiza sobre los ND presentes en la imagen. De esta forma, pueden distinguirse las siguientes fases: 1) definición digital de las categorías (fase de entrenamiento), 2) agrupación de los píxeles de la imagen en una de esas categorías (fase de asignación), y 3) comprobación y verificación de resultados. Trataremos aquí de las dos primeras, reservando la tercera para un capítulo independiente, puesto que las técnicas de verificación son aplicables tanto a la interpretación digital como a la visual.

2.2. Fase de entrenamiento

2.2.1. *Conceptos básicos*

Para que una fotografía aérea pueda ser interpretada en detalle es preciso que exista una experiencia previa, que nos permita identificar cada una de las categorías de interés por una serie de rasgos, como son tono, textura, situación o tamaño. Es posible distinguir entre matorral y arbolado, gracias a que éste tiene una textura más rugosa; mientras la separación entre agua y suelos descubiertos se realiza sobre la diferencia de tonalidad. De la misma forma, la clasificación digital se inicia caracterizando los

patrones que definen en la imagen las distintas categorías objetivo. Por cuanto se trata de una clasificación basada en los valores numéricos de los píxeles, esta caracterización también debe ser numérica; esto es, se trata de obtener el ND, o mejor aún el rango de ND, que identifica a cada categoría, para todas las bandas que intervienen en la clasificación.

Como ya hemos visto a lo largo de esta obra, diversos factores introducen una cierta dispersión en torno al comportamiento espectral medio de cada cubierta. Esto implica que las distintas categorías no se definen por un sólo ND, sino por un conjunto de ND, más o menos próximos entre sí. En términos de su clasificación digital, esto supone que existe una cierta dispersión en torno al ND medio de cada categoría, más o menos significativa según las clases que se consideren y la propia complejidad del paisaje donde éstas se asienten. Por ello, la fase de entrenamiento resulta ciertamente compleja: se trata de definir con rigor cada una de las categorías que pretendan discriminarse, teniendo en cuenta su propia variabilidad en la zona de estudio.

Este objetivo se logra seleccionando una muestra de píxeles de la imagen, que representen adecuadamente a las categorías de interés. A partir de esos píxeles pueden calcularse los ND medios y la variabilidad numérica de cada categoría, en todas las bandas que intervienen en la clasificación. Al igual que en cualquier otro muestreo, el objetivo de esta fase es obtener los resultados más precisos con el mínimo coste. En otras palabras, identificar debidamente las distintas categorías, reduciendo a lo imprescindible los trabajos de campo. Al igual que en otras aplicaciones del muestreo, las estimaciones posteriores se basan sobre la muestra seleccionada, por lo que una incorrecta selección de ésta conducirá inexorablemente a pobres resultados en la clasificación posterior. Varios autores han comprobado que los resultados de la clasificación están mucho más influidos por la definición previa de las categorías, que por el criterio con el que éstas son posteriormente discriminadas (Gong y Howarth, 1990*b*; Hixson *et al.*, 1980; Story y Campbell, 1986). En definitiva, la fase de entrenamiento constituye la columna vertebral de la clasificación numérica.

Tradicionalmente se han dividido los métodos de clasificación en dos grupos: supervisado y no supervisado, de acuerdo a la forma en que son obtenidas las estadísticas de entrenamiento. El método supervisado parte de un conocimiento previo del terreno, a partir del cual se seleccionan las muestras para cada una de las categorías. Por su parte, el método no supervisado procede a una búsqueda automática de grupos de valores homogéneos dentro de la imagen. Queda al usuario, en este caso, la labor de encontrar correspondencias entre esos grupos y sus categorías de interés. Volviendo al paralelismo con la fotointerpretación, podríamos afirmar que en ésta el método supervisado es el más habitual, por cuanto se identifican sobre unos fotogramas-tipo las características de cada clase, para luego delimitar, en el resto, las zonas que se ajustan a esas características. El método no supervisado supondría, en primer lugar, identificar sobre la fotografía aérea zonas homogéneas en cuanto a tonos, textura, disposición, etc., para luego asignarlas a una de las clases temáticas establecidas en la leyenda.

Para iluminar el sentido de ambos métodos, puede ser conveniente introducir una pequeña reflexión sobre el tipo de categorías que pueden intervenir en una clasificación temática. Suelen distinguirse, a este respecto, dos tipos de clases: informacionales y espectrales (Chuvieco, 1986; Labrandero, 1978). Las primeras son las que consti-

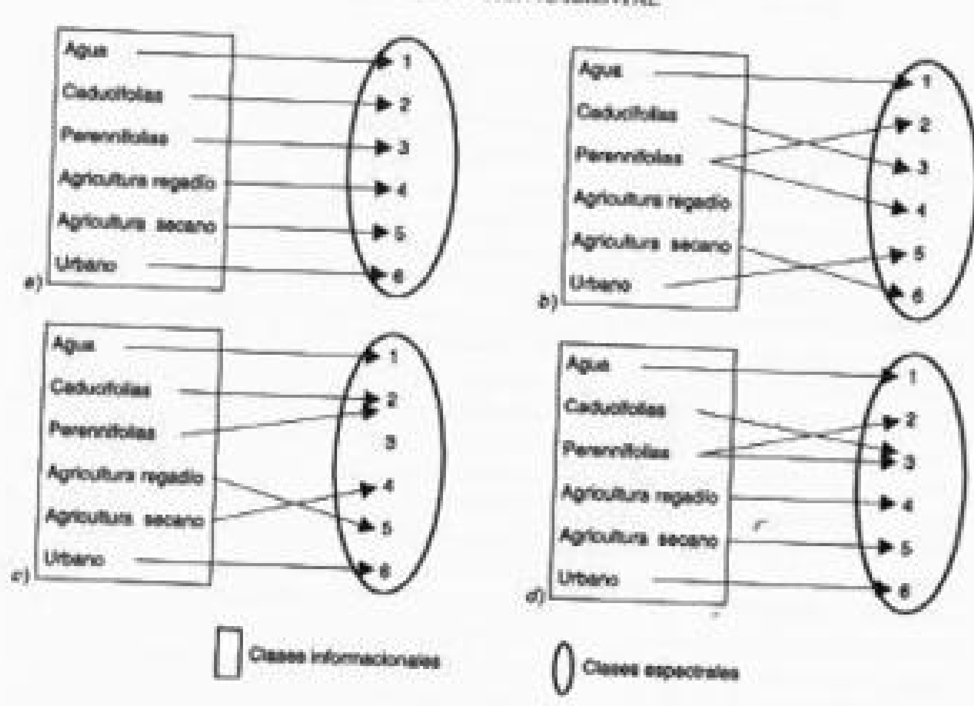


FIG. 7.33. *Relaciones entre clases informacionales y espectrales.*

tuyen la leyenda de trabajo que pretende deducir el intérprete (tipos de ocupación del suelo, por ejemplo). Las segundas corresponden a los grupos de valores espectrales homogéneos dentro de la imagen, en función de ofrecer una reflectividad similar, para las bandas consideradas y en la fecha concreta de la imagen. Las categorías informacionales se establecen por el usuario, mientras las espectrales se deducen de los ND presentes en la imagen.

Idealmente habría de producirse una correspondencia biunívoca entre las dos (fig. 7.33*a*); esto es, que a cada clase de cobertura le corresponda un único grupo espectral, y que cada grupo espectral corresponda a una sola clase temática. Desgraciadamente, este caso es muy poco frecuente, produciéndose, normalmente, alguna de las siguientes situaciones:

1. Que una categoría de cubierta esté expresada en varias clases espectrales (fig. 7.33*b*). Por ejemplo, el pinar según su emplazamiento podría aparecer en dos grupos: uno correspondiente a solana y otro a umbría; o el agua en distintos tipos, de acuerdo a su profundidad o turbidez. Para evitar los problemas que puede implicar esa dispersión espectral en los resultados posteriores convendría refinar el muestreo, bien incluyendo en las clases esa heterogeneidad, bien creando sub-clases, que luego serán fundidas —tras la clasificación— en un solo grupo. Esto evita contar con clases muy heterogéneas espectralmente, fácilmente sujetas por tanto a confusión con otras similares.

2. Otra cosa sería que dos o más categorías informacionales compartan una sola

clase espectral (fig. 7.33*c*). Esto implicaría, en pocas palabras, que algunas categorías de la leyenda no sean discriminables, a partir de la imagen con que se cuenta, sin grave peligro de confusión. En este caso se pueden plantear varias opciones para solucionar el problema. La más sencilla sería optar por una clave más general, evitando descender a un nivel de desagregación no abordable a partir de esos datos. Por ejemplo, podría optarse por una clase denominada coníferas, en lugar de distinguir distintos tipos de pinar, o urbana, frente a distintas densidades de edificación. Ahora bien, esa solución en algunos casos no es aceptable, bien porque la confusión se dé entre categorías que no son asimilables temáticamente (por ejemplo, superposición entre núcleos rurales y rastrojeras, en imágenes de verano), bien porque las categorías objetivo sean un requisito imprescindible del trabajo (p. ej., un inventario forestal no puede aceptarse si no se discriminan un cierto número de especies). En estos casos, habría que intentar otras soluciones, como incluir en la clasificación una imagen perteneciente a otra fecha del año, en donde la separación entre categorías problemáticas sea posible (contraste primavera-verano, para cubiertas vegetales), o acudir a criterios no espectrales, como pueden ser los derivados de la textura o situación espacial, o añadir alguna variable auxiliar (relieve, suelos, etc.).

3. Por último, puede también ocurrir que varias clases informacionales compartan clases espectrales (fig. 7.33*d*). En este caso convendría replantear la estrategia de trabajo, o acudir a las soluciones parciales comentadas en párrafos anteriores.

A la luz de este comentario, parece claro que el método supervisado pretende definir clases informacionales, mientras el no supervisado tiende a identificar las clases espectrales presentes en la imagen. De los párrafos anteriores también puede deducirse que ninguno de los dos métodos proporciona una solución inmediata a todos los problemas que entraña una clasificación digital. Por un lado, el método supervisado puede tacharse de subjetivo y artificial, pues puede «forzarse» al algoritmo a discriminar categorías que no tengan una claro significado espectral. Por otro, el método no supervisado proporciona en ocasiones resultados de difícil interpretación, poco conectados con las necesidades del usuario final del producto. Asimismo, resulta poco claro que este método sea realmente capaz de identificar las agrupaciones naturales de la imagen. De ahí la diversidad de algoritmos y de parámetros de control revisados en la literatura, como más tarde tendremos ocasión de analizar.

En resumen, la elección entre uno y otro método dependerá de los datos y medios disponibles y de las propias preferencias personales (Townshend y Justice, 1981).

2.2.2. *Método supervisado*

El método supervisado parte de un cierto conocimiento de la zona de estudio, adquirido por experiencia previa o por trabajos de campo. Esta mayor familiaridad con el área de interés permite al intérprete delimitar sobre la imagen unas áreas suficientemente representativas de cada una de las categorías que componen la leyenda. Estas áreas se denominan, en la bibliografía anglosajona, *training fields* (áreas de entrenamiento). El término indica que tales áreas sirven para «entrenar» al programa de clasificación en el reconocimiento de las distintas categorías. En otras palabras, a partir de

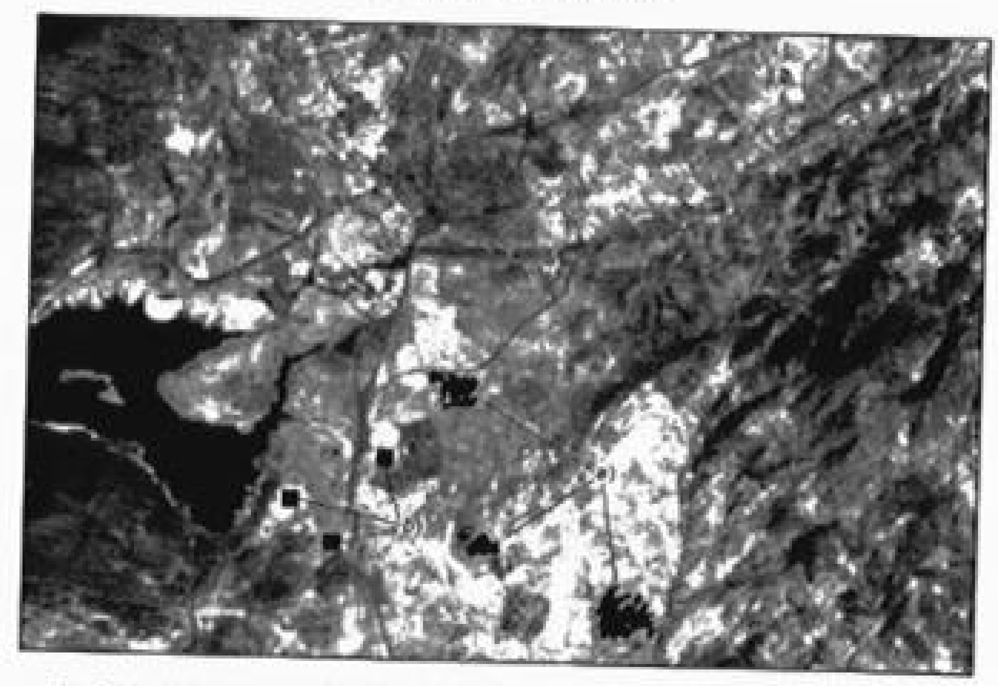


FIG. 7.34. *Selección de píxeles de entrenamiento por semillado (a) y utilizando polígonos regulares (b).*

ellas se caracterizan cada una de las clases, para asignar más tarde el resto de los píxeles de la imagen a una de esas categorías en función de la similitud de sus ND con los extraídos como referencia.

La mayor parte de los equipos de ADI permiten localizar interactivamente las áreas de entrenamiento. Con ayuda del digitizador o ratón electrónico, el usuario introduce sobre la pantalla los vértices que definen cada una de estas áreas, asignándolas a una de las categorías definidas previamente en la leyenda. También pueden seleccionarse los píxeles que formarán parte de un área de entrenamiento a partir de un método semi-automático, conocido como «semillado» (fig. 7.34). En lugar de digitizar un polígono completo, basta que el intérprete localice un píxel central, a partir del que se agregan los píxeles vecinos, en función de su proximidad espectral y espacial al introducido como semilla, hasta formar un polígono completo. La ventaja sobre el criterio anterior se basa en la garantía de que los píxeles seleccionados de esta forma tendrán características espectrales similares al píxel semilla, evitándose así añadir ruido involuntario a la definición de las clases espectrales. Los parámetros para asignar los píxeles vecinos al de origen dependen de cómo crezca la varianza global de la muestra, señalando el intérprete algún valor límite, según el conocimiento que tenga de la heterogeneidad de la categoría que está delimitando.

Para una localización más precisa de estas áreas de entrenamiento pueden ser de gran ayuda los trabajos de campo y otros documentos auxiliares —como la fotografía aérea o la cartografía convencional—, teniendo en la mente que debe tratarse de ejemplos suficientemente representativos y homogéneos de la clase que pretende definirse.

Acabada la delimitación de una parcela de entrenamiento, pueden seleccionarse otras para la misma categoría, o bien culminar con ella la definición de esa clase. En general, resulta conveniente seleccionar varias áreas por categoría, a fin de reflejar adecuadamente su variabilidad en la zona de estudio.

Independientemente del método elegido para seleccionar las áreas de entrenamiento, conviene que exista un control de campo suficiente, en fecha próxima a la adquisición de la imagen, y mejor aún si es simultánea, para garantizar la consistencia entre lo medido en el terreno y por el sensor. En estos trabajos será muy interesante realizar algunas medidas radiométricas, aprovechando la creciente disponibilidad de radiómetros portátiles (fig. 7.35), lo que permite interpretar con más rigor la señal recibida por el sensor o seleccionar las bandas más adecuadas para el tratamiento (Barret y Curtis, 1999*b*; Milton *et al.*, 1995).

Finalizada la selección de las áreas de entrenamiento, se calculan las estadísticas elementales de cada categoría: media, rango, desviación típica, matriz de varianza-covarianza, etc., a partir de los ND de todos los píxeles incluidos en las áreas de entrenamiento de esa clase. Lógicamente, este cálculo se aplica a todas las bandas que intervendrán en la clasificación. En definitiva, se asume que las áreas de entrenamiento son fieles representantes de las distintas categorías, y que, por tanto, las medidas extraídas a partir de sus ND definen convenientemente a esas clases. De aquí que sea crucial su correcta selección, ya que de otro modo se estaría forzando al algoritmo a clasificar áreas heterogéneas. En consecuencia, la clasificación estaría viciada de partida, al pretender discrimi-



FIG. 7.35. *El empleo de un radiómetro de campo permite verificar el comportamiento espectral de una cubierta.*

nar categorías con escaso significado espectral. Conviene especialmente evitar áreas de entrenamiento que puedan ser heterogéneas, o clases espectrales presentes en la imagen que no se hayan identificado con ninguna clase de entrenamiento.

Un último aspecto a considerar en la selección de las áreas de entrenamiento se refiere a los requisitos estadísticos que garantizan el grado de representatividad de las distintas categorías. Como antes se comentó, este proceso implica una forma peculiar de muestreo espacial. Por ello conviene tener en cuenta algunos criterios habituales en este tipo de técnicas para elegir el tamaño y la distribución más idónea de la muestra, así como para realizar estimaciones a partir de ella.

En cuanto al tamaño, se requiere seleccionar un mínimo de $m + 1$ píxeles por categoría, siendo m el número de bandas que integran el análisis (Schowengerdt, 1997). Conviene, no obstante, superar con creces este límite mínimo. Diversos autores recomiendan seleccionar un número de píxeles comprendido entre 10 m y 100 m por categoría (Jensen, 1996; Mather, 1998, sugiere 30 m). Este número parece fácilmente accesible con los sensores que habitualmente han servido de entrada en la clasificación, pero puede ser más complicado si se parte de equipos hiperespectrales, en donde el número de bandas de entrada sea muy numeroso. Esto sugiere, de nuevo, el interés por seleccionar adecuadamente las bandas más convenientes para la clasificación.

Por otro lado, ese número mínimo de píxeles se relaciona estrechamente con el grado de asociación espacial entre los ND de la imagen. El muestreo convencional considera que las muestras seleccionadas son aleatorias e independientes. Como antes indicamos, esta asunción no es válida en nuestro caso, por cuanto una parcela de entrenamiento alberga a píxeles vecinos, afectados por el fenómeno de la auto-correlación espacial. En pocas palabras, esta asociación, comprobada en diversos trabajos sobre imágenes de satélite (Congalton, 1988*a*), supone que la información original extraída de un número de píxeles contiguos es menor que si fue obtenida a partir de otros dispersos. En suma, resulta más conveniente elegir varios campos de pequeño tamaño que uno solo de mayores dimensiones, ya que tenderá a infravalorarse la variabilidad de esa categoría. También se puede optar por seleccionar píxeles aleatoriamente, dentro de campos de mayor tamaño, en lugar de admitirlos todos (Campbell, 1996; Mather, 1998). Otros autores recomiendan seleccionar píxeles aislados de cada categoría, en número suficiente para estimar adecuadamente la variabilidad espectral de dicha clase (Gong y Howarth, 1990*b*). Este criterio puede ser recomendable cuando existe suficiente control del terreno. En zonas de difícil acceso resulta poco operativo.

Respecto a la distribución, conviene tener en cuenta las propias características de la imagen, intentando abarcar las variaciones espaciales que se presentan en cada categoría: su orientación, pendiente, densidad, vigor, contenido de humedad, tipo de suelo, etc. En este sentido, varios autores han subrayado que la variabilidad de una cubierta es directamente proporcional a la resolución del sensor (Cushnie, 1987). Dicho de otro modo, cuanto mayor sea el detalle espacial registrado en la imagen, mayor será también su sensibilidad para detectar las variaciones internas de una categoría, ocultas de otra forma bajo un píxel de mayor tamaño. Por cuanto a mayor heterogeneidad, mayor mezcla con clases similares —y, en última instancia, mayor riesgo de confusiones en la asignación posterior—, un incremento en la resolución espacial puede complicar la clasificación digital. Este hecho, que parece contradecir el sentido común (mayor resolución espacial, mayor fiabilidad), fue puesto de manifiesto ya hace algunos años por diversos

autores, que lo denominaron «*scene noise*», ruido de la escena (Markham y Townshend, 1981). El efecto se ha comprobado con más nitidez en los tipos de cubierta más heterogéneos, como es el caso de las áreas urbanas, en donde un píxel de mayor tamaño facilita adquirir una señal promedio de distintos componentes, mientras cuanto más se reduzca el píxel, los efectos de frontera son más intensos (Toll, 1984). Por el contrario, en categorías agrícolas y forestales, ese efecto es menos nítido, siendo más convenientes las imágenes de alta resolución (Hopkins *et al.*, 1988; Irons y Kennard, 1986).

La delimitación de las áreas de entrenamiento sobre la imagen Torrel00 se realizó en nuestro caso a partir del trabajo de campo. Para facilitar el carácter didáctico de la exposición, solamente hemos seleccionado 7 categorías: áreas urbanas, pastizales, pinar-encinar (los caducifolios no tienen todavía hojas en esta fecha), matorral, láminas de agua, suelos descubiertos y cultivos de secano (los de regadío no están presentes en esta época del año). La figura 7.36 recoge la localización de los campos de entrenamiento seleccionados; como podrá observarse se trata de pequeñas superficies, intentando recoger adecuadamente la diversidad de rasgos espectrales en el área de estudio.

2.2.3. *Método no supervisado*

Este método se dirige a definir las clases espectrales presentes en la imagen. No implica ningún conocimiento del área de estudio, por lo que la intervención humana se centra más en la interpretación que en la consecución de los resultados.

En esta estrategia se asume que los ND de la imagen forman una serie de agrupaciones o conglomerados (*clusters*), más o menos nítidos según los casos. Estos grupos

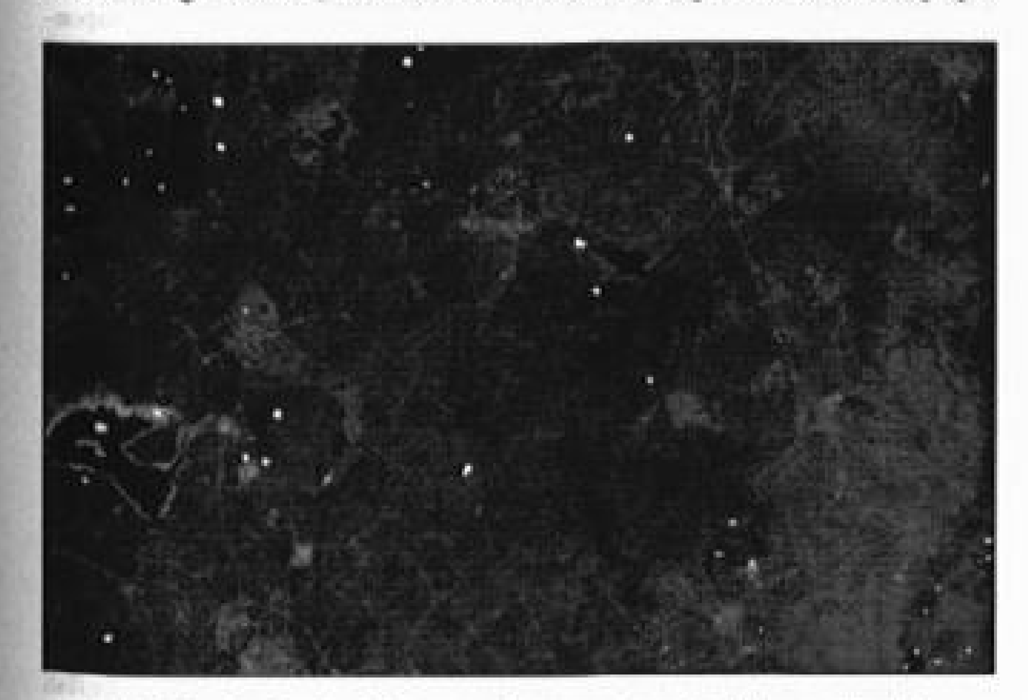


FIG. 7.36. *Localización de los campos de entrenamiento sobre la imagen Torrel00.*

equivaldrían a píxeles con un comportamiento espectral homogéneo y, por tanto, deberían definir clases temáticas de interés. Desgraciadamente, como se vio más arriba, estas categorías espectrales no siempre pueden equipararse a las clases informacionales que el usuario pretende deducir, por lo que resta a éste interpretar el significado temático de esas categorías espectrales.

El método para definir los agrupamientos espectrales es muy similar al empleado en otras técnicas de clasificación automática de datos (Hand, 1981; Johnston, 1978). Se basa en la selección de tres parámetros: 1) variables que intervienen en el análisis; 2) criterio para medir la similitud o distancia entre casos, y 3) criterio para agrupar los casos similares.

En nuestro contexto, las variables son las bandas espectrales seleccionadas para la clasificación, ya sean éstas originales o fruto de alguna transformación. Los casos son los píxeles que componen la imagen, cada uno de ellos definido por tantos ND como bandas intervienen en el análisis. En este espacio multivariado se trata de encontrar los grupos de píxeles con ND similares, para luego equipararlos con alguna de las clases informacionales de nuestra leyenda.

El método para encontrar esos grupos homogéneos puede ilustrarse con el caso más simple, en el que estuviéramos trabajando con dos bandas (IRC y R, por ejemplo). En un gráfico bivariado aparecerían tantos puntos como píxeles, localizados de acuerdo a sus ND en cada banda (fig. 7.37). El gráfico evidencia la existencia de agrupaciones de píxeles, con ND similares en las dos bandas, que podrían identificar clases temáticas de interés. Por ejemplo, los puntos situados en el vértice inferior izquierdo corresponderían a píxeles con ND bajos en las dos bandas *(c)*, los situados en el superior derecho serían píxeles con altos valores en ambas bandas *(b)*, mientras los correspon-

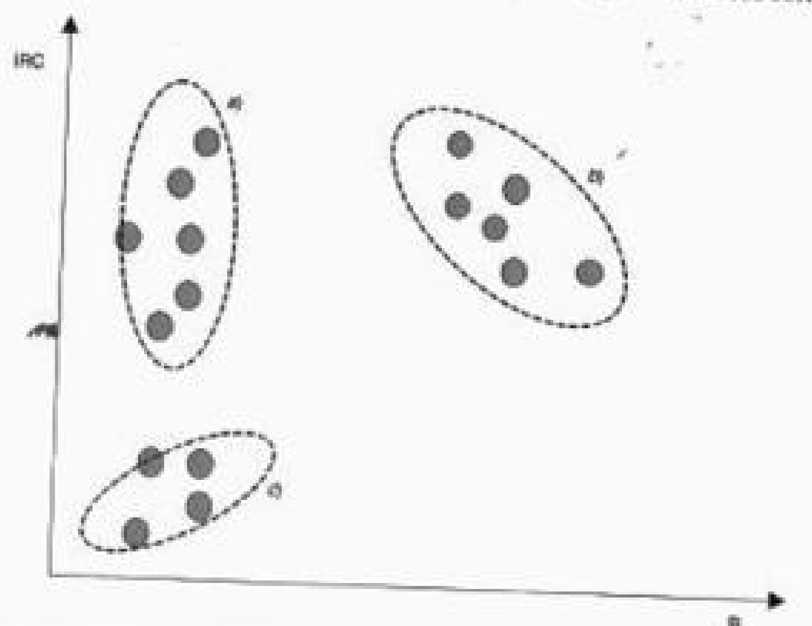


FIG. 7.37. *Esquema de la clasificación no supervisada.*

dientes al extremo superior izquierdo implican ND bajos en la banda R y altos en el IRC *(a)*. En estas regiones del espectro podríamos identificar estos grupos como pertenecientes a agua, suelos desnudos o vegetación, respectivamente, aunque en esta fase sólo nos interesa conocer que se trata de grupos homogéneos y distintos entre sí.

La delimitación de cada grupo espectral se inicia señalando dos criterios: uno que mida la similitud entre píxeles, y otro que marque las condiciones del proceso de agrupamiento. En cuanto al primer aspecto, se han propuesto diversos criterios para medir la distancia entre píxeles. El más utilizado se basa en la distancia euclidiana:

$$d_{a,b} = \sqrt{\sum_{i=1,m} (ND_{a,i} - ND_{b,i})^2} \qquad [7.29]$$

donde $d_{a,b}$, indica la distancia entre dos píxeles cualquiera *a* y *b*; $ND_{a,i}$ y $ND_{b,i}$, los niveles digitales de esos píxeles en la banda *i*, y *m* el número de bandas. También pueden utilizarse otros criterios para medir la distancia entre píxeles, como sería el caso de la distancia media o la de Mahalanobis (Rebollo y Orti, 1980), si bien la distancia euclidiana resulta la más habitual en este tipo de aplicaciones.

En cuanto al algoritmo de agrupamiento, las opciones también son muy numerosas. Uno de los más extendidos es el denominado ISODATA (Duda y Hart, 1973), gracias a contar con un mecanismo iterativo bastante sólido. En esencia, este algoritmo procede a partir de las siguientes fases:

1. Se señalan una serie de centros de clase, de acuerdo al número y forma indicados por el usuario.
2. Se asignan todos los píxeles de la imagen al centro de clase más próximo, utilizando el criterio de distancia antes comentado.
3. Se calculan de nuevo los centros de clase, teniendo en cuenta los valores de todos los píxeles que se le hayan incorporado en la fase anterior.
4. Se reordenan los centros de clase en función de los parámetros de control indicados por el usuario (distancia mínima entre grupos, tamaño mínimo de un grupo, varianza máxima de un grupo y número de grupos).
5. Se vuelven a asignar todos los píxeles de la imagen al centro más cercano, el cual —debido al desplazamiento registrado en (3)— no tiene por qué coincidir con la asignación realizada en (2).
6. Si el número de píxeles que han cambiado de categoría es inferior al señalado por el usuario se termina el proceso; en caso contrario, se retorna a la fase (3).

En cada iteración el algoritmo se pregunta: ¿se ha alcanzado el número máximo de grupos para interrumpir el agrupamiento?, ¿algún grupo tiene un número de píxeles inferior al mínimo señalado, en cuyo caso se suprime?, ¿algún grupo está a una distancia inferior a la mínima señalada entre grupos para realizar una fusión?, ¿algún grupo cuenta con una varianza superior a la máxima señalada para que sea dividido?

Desde el punto de vista estadístico, este algoritmo parece bastante adecuado para delimitar los grupos de valores homogéneos dentro de la imagen (Rebollo y Ortí, 1980; Mather, 1998), si bien pueden darse en ocasiones bucles indefinidos, cuando los

parámetros de control no están bien definidos y el algoritmo entra en una cadena de separaciones y fusiones interminable.

Otro problema, más habitual para el usuario, atañe a la elección de los parámetros de control más convenientes para la imagen que se interpreta, puesto que habitualmente no conocemos, de partida, el número de grupos espectrales presentes en la imagen, ni el valor idóneo de dispersión interna o de distancia entre grupos. De esta forma, el análisis no supervisado se convierte en un proceso exploratorio, en donde el intérprete establece unos valores arbitrarios que se van modificando a la vista de los resultados.

Finalmente, el método no supervisado también presente como inconveniente el notable volumen de cálculo que precisa. Habitualmente, un buen agrupamiento se consigue tras un número alto de iteraciones, por lo que este criterio resulta muy lento para clasificar imágenes muy extensas. Parece más razonable, en consecuencia, extraer una muestra sistemática de píxeles (1 de cada 4, 8 o 16, por ejemplo) para calcular sobre ellos los centros de clase, que luego se clasifiquen con alguno de los criterios de asignación que veremos en el siguiente epígrafe. En este caso, no se clasifica la imagen completa, pero sí pueden identificarse los grupos presentes en ella, objetivo último del método no supervisado.

Con este enfoque, si bien algunos autores consideran el método no supervisado como una forma específica de clasificación —esto es, como una estrategia completa, que abarca tanto la fase de entrenamiento como la asignación de los píxeles de la imagen a las categorías de la leyenda—, a nuestro juicio supone más bien una forma alternativa de obtener las estadísticas de entrenamiento. En otras palabras, el análisis no supervisado se orienta no tanto a la clasificación de la imagen, como a definir precisamente los grupos o categorías que intervendrán en la clasificación propiamente dicha. En este sentido, el método no supervisado podría considerarse como exploratorio (Mather, 1998), dirigido a deducir las clases espectrales presentes en la imagen. Eso es especialmente importante cuando se adoptan criterios de clasificación que asumen una distribución normal de los datos. El análisis no supervisado podría indicarnos si efectivamente esas clases informacionales tienen un sentido espectral claro o, por el contrario, algunas de ellas presentan una distribución bimodal o multimodal (o, lo que es lo mismo, se presentan en varias categorías espectrales).

Como en el caso del método supervisado, es necesario analizar los píxeles incluidos en cada grupo para obtener sus medidas estadísticas elementales: media, desviación típica, mínimo, máximo, etc., que servirán para abordar la fase posterior de clasificación.

En el caso de la imagen Torrel00, el análisis no supervisado se realizó sobre las 6 bandas no térmicas del sensor, extrayendo una muestra de 1 de cada 8 líneas y columnas. Se señalaron como parámetros de control los siguientes: 30 iteraciones, entre 12 y 20 grupos, 5 como umbral de tamaño mínimo de cada grupo, 2 desviaciones típicas como dispersión máxima en un grupo para dividirlo, y 1 como distancia mínima entre grupos para que fueran unidos. Con este esquema se generaron 17 clases temáticas, que fueron comparadas con las estadísticas generadas del proceso supervisado para proceder a la fase de asignación.

2.2.4. *Métodos mixtos*

Como ya apuntamos, tanto el método supervisado como el no supervisado cuentan con ventajas e inconvenientes (Cihlar *et al.*, 1998; Hoffer y Swain, 1980; Justice y Townshend, 1981). El primero resulta muchas veces subjetivo, pues el usuario establece *a priori* unas categorías sin valorar las características espectrales de la imagen. El segundo no garantiza que las clases deducidas tengan significado para el usuario del producto, además de ser de difícil verificación.

Con objeto de paliar los inconvenientes de ambos métodos se han propuesto diversas alternativas que los combinan de alguna forma. Estos métodos mixtos pueden agruparse en dos bloques:

1. Por un lado, se sitúan aquellos trabajos que emplean el análisis supervisado para «guiar» al no supervisado. En este caso, el conocimiento del intérprete se utiliza para orientar la búsqueda de esos grupos espectrales homogéneos. Por ejemplo, puede aplicarse el método no supervisado a áreas de la imagen con una cobertura conocida, lo que facilitaría la definición espectral de dicha cubierta (Hoffer y Fleming, 1978; Justice y Townshend, 1981). Otra forma de orientar el análisis no supervisado consiste en introducir los ND medios de las categorías de interés —obtenidas a partir de las áreas de entrenamiento— como centros iniciales de grupo. Gracias a ello, el proceso iterativo de búsqueda se reduce notablemente, a la vez que se predispone la formación de grupos con un significado temático.

2. Por otro lado, el análisis supervisado y el no supervisado pueden combinarse gracias a aplicarlos separadamente sobre la misma imagen, para luego sintetizar las medidas extraídas por ambos. Se asume que las categorías deducidas por los dos métodos pueden complementarse mutuamente, ganando en significado espectral e informacional las clases resultantes. Algunos autores, por ejemplo, emplean el análisis no supervisado para estratificar la imagen, quedando el supervisado para las áreas no clasificadas previamente (Bruneau y Gautier, 1981; Núñez *et al.*, 1983). También pueden combinarse categorías deducidas por los dos métodos, empleando un algoritmo de agrupación jerárquico. Esto permite crear un nuevo conjunto de categorías en donde se combina la información obtenida por ambos métodos (Chuvieco y Congalton, 1988). En breves palabras, se trata de clasificar conjuntamente las categorías deducidas por el análisis supervisado y no supervisado sobre la misma imagen. Esta clasificación conjunta permite obtener tres tipos de grupos: unos formados por categorías supervisadas y no supervisadas; otros, sólo por categorías supervisadas, y un tercero, sólo por categorías no supervisadas. El primer grupo identifica aquellas clases seleccionadas por el intérprete que cuentan con un significado espectral claro. El segundo corresponde a clases informacionales con escaso significado espectral. Éstas, al menos *a priori*, resultarán de difícil asignación, ya que no se identifican con agrupaciones naturales de la imagen. Por último, el tercer grupo se refiere a clases espectrales no asimilables a la leyenda propuesta por el usuario. A partir del análisis de estos dos últimos grupos, el intérprete puede refinar el esquema de clasificación propuesto inicialmente.

Otro método híbrido propuesto en los últimos años parte de generar una compresión espectro-espacial de las bandas de entrada utilizando la distribución de frecuen-

cias en cada banda y técnicas de contexto, de cara a generar centros de grupo automáticamente. Estos centros sirven de semilla para el primer agrupamiento, que se realiza desde cada píxel de la imagen al centro más cercano. Los grupos resultantes se combinan utilizando criterios de mínima distancia espacial (adyacencia) y espectral (ángulo del vector que une los centros y diferencia cuadrática entre sus ND). Una vez obtenidos los grupos deseados, que en su última fase se combinan de acuerdo a la supervisión que realiza el intérprete, éste etiqueta el resultado final (Cihlar *et al.*, 1998).

2.2.5. *Análisis de las estadísticas de entrenamiento*

Independientemente del método empleado en definir la fase de entrenamiento, antes de abordar el proceso de clasificación propiamente dicho conviene reflexionar sobre la separabilidad real de las categorías seleccionadas. En otras palabras, es preciso evaluar la viabilidad de que esas categorías puedan clasificarse sin grave riesgo de error. Si se comprueba que dos o más son muy similares, sería muy probable que haya confusión entre ellas, por lo que resultaría aconsejable: 1) confirmar que las estadísticas de entrenamiento han sido correctamente deducidas; 2) adoptar una leyenda más general, con nuevas categorías que supongan una mezcla de las que ofrecen mayor riesgo de confusión; 3) recabar información auxiliar o imágenes de otras fechas.

Existen varios métodos —tanto gráficos como numéricos— para evaluar las estadísticas de entrenamiento. Entre los gráficos, el más elemental es un diagrama de signaturas, donde figuran, en abscisas, las bandas que intervienen en el análisis, mientras en ordenadas los ND medios de cada categoría. Conviene no confundir este gráfico con las curvas espectrales presentadas en el capítulo 2. Por un lado, aquí no se incluyen valores de reflectividad, sino ND, salvo que se haya hecho una previa conversión de ND originales a reflectividad, como vimos en el anterior capítulo. Por otro, la señal recogida por el sensor corresponde a la anchura completa de la banda, y no sólo a su centro. Con estas salvedades, este gráfico resulta muy útil para proporcionar una primera valoración de las tendencias espectrales de cada categoría. Identifica, además, aquellas bandas en las que manifiesta un comportamiento peculiar respecto a clases vecinas. Las líneas paralelas y próximas indican un probable solape entre categorías, mientras las intersecciones entre líneas manifiestan las bandas donde es más probable separar a las categorías que representan.

En el caso de la imagen de Torrelaguna, la tabla 7.6 recoge las medidas estadísticas elementales de las áreas de entrenamiento previamente seleccionadas. En este caso

Tabla 7.6. *Media (x) y desviación típica (DT) de las categorías seleccionadas (ND = reflectividad · 100)*

	Urbano		Pastizal		Matorral		Pinar-encinar		Suelo		Cultivo		Agua	
Banda ETM	x	DT	x	DT	x	DT	x	DT	x	DT	x	DT	x	DT
1	10,45	2,20	5,57	0,77	5,31	1,95	1,35	0,61	13,16	5,03	4,49	0,83	2,82	0,41
2	11,12	1,93	7,51	0,68	6,29	2,32	2,49	0,79	15,74	5,66	5,39	1,08	3,21	0,29
3	15,65	2,66	9,44	1,12	9,52	3,94	3,32	0,83	22,76	7,64	5,84	1,28	3,29	0,38
4	19,33	2,54	28,80	3,85	16,80	4,02	17,53	3,86	25,71	4,77	30,84	3,28	1,60	0,19
5	21,88	2,59	26,50	1,26	22,62	6,67	9,39	1,75	34,34	8,71	14,87	2,11	2,95	0,18
7	17,04	2,70	15,54	1,54	15,18	4,73	5,42	0,94	26,76	8,15	7,75	1,15	2,65	0,27

Tabla 7.7. *Coeficiente de variación de las categorías seleccionadas*

Banda ETM	Urbano	Pastizal	Matorral	Pinar-Encinar	Suelo	Cultivo	Agua
1	21,02	13,83	36,70	45,05	38,24	18,44	14,67
2	17,37	9,07	36,86	31,83	35,97	19,98	8,99
3	16,98	11,86	41,37	25,86	33,58	21,88	11,51
4	13,14	13,37	23,92	22,01	18,55	10,63	11,54
5	11,81	4,77	29,50	18,64	25,37	14,17	6,11
7	15,85	9,88	31,13	17,26	30,47	14,84	10,14

trabajaremos con las imágenes ya corregidas a reflectividad (utilizando el método de Chávez: cap. 6, apdo. 6.2.3.2), por lo que los valores sí son comparables a los que obtendríamos a partir de bibliotecas espectrales o espectro-radiómetros.

En esta tabla, el valor medio nos informa de la tendencia espectral de esa cubierta, mientras la desviación típica refiere al grado de homogeneidad que aparece en torno a ese valor central. Hemos incluido también el coeficiente de variación (definido como la importancia de la desviación típica en relación a la media de cada categoría), puesto que nos permite entender mejor la variabilidad relativa de las distintas cubiertas (tabla 7.7).

Siendo consciente de la gran heterogeneidad de las categorías urbanas, procuramos seleccionar únicamente áreas de cobertura construida homogénea, con objeto de evitar una sobre-dimensión de esta categoría. Gracias a eso, los valores de desviación típica de las áreas urbanas son bastante bajos. Entre las categorías de vegetación destacan los altos valores de la mezcla pinar-encinar, lo que nos indica que se trata de una categoría mixta que puede presentar problemas para su posterior discriminación. Los suelos también ofrecen ND bastante heterogéneos, en este caso por la diversidad de condiciones litológicas en el área de estudio. El agua, como parece lógico, ofrece los valores más homogéneos, pese a haber seleccionado muestras en varios embalses.

A partir de estos parámetros puede construirse el gráfico de signaturas (fig. 7.38), tal y como se describió más arriba. Se aprecia ya una primera valoración de los rasgos

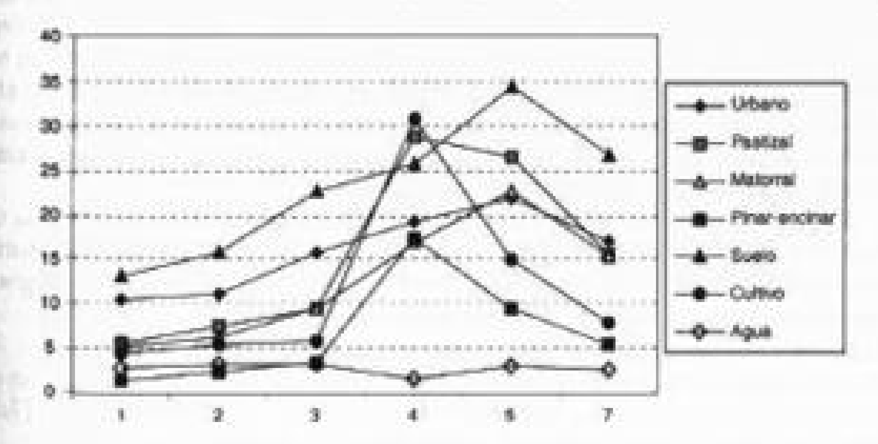


Fig. 7.38. *Gráfico de signaturas espectrales para las categorías seleccionadas.*

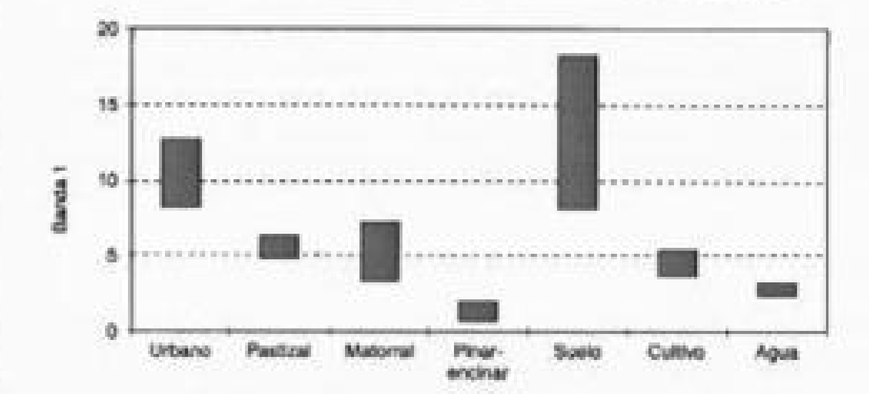
espectrales de cada tipo de cobertura. El agua ofrece el comportamiento más peculiar, con valores inferiores según se avanza hacia el SWIR. Los cultivos también ofrecen una clara diversidad, al ser grande su contraste entre las bandas 4 y 3-5. Similar patrón ofrecen los pinares-encinares, aunque los valores de reflectividad son más bajos. Los suelos descubiertos presentan el ND más alto en todas las bandas, salvo la IRC, siendo más prominente en la 5, mientras las superficies urbanas presentan un comportamiento similar, aunque con menor reflectividad en todas las bandas. Los pastizales ofrecen un comportamiento similar a los cultivos en esta época del año, si bien con valores más altos en las bandas cortas.

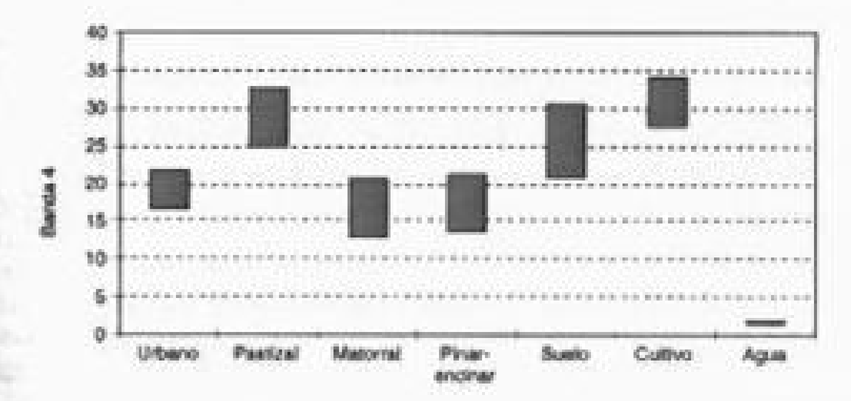
Desgraciadamente, la realidad es más compleja de lo que ofrece este gráfico, puesto que aquí sólo se refleja la tendencia media, sin considerar la variación propia de cada categoría, principal responsable de las confusiones con otras clases vecinas. Una idea más clara de estos problemas puede obtenerse a partir de un gráfico de *solape espectral*. Se trata de un diagrama de barras que recoge, en cada banda y para cada categoría, el rango digital cubierto por la media ± una o dos desviaciones típicas. En el caso de la figura 7.39 hemos recogido los solapes entre tres bandas bastante contrastadas (1, 4 y 5). Observamos cómo ciertas cubiertas muestran rangos similares en algunas bandas (p. ej., el agua y las cubiertas vegetales en la banda 1), pero se separan nítidamente en otras (en la 4, especialmente), mientras otras manifiestan una mayor similitud en todas ellas (urbano-matorral). El suelo descubierto tiende a presentar los valores mas altos, lo que permite separarlo bien en la mayor parte de las bandas, aunque hay pequeñas confusiones en todas ellas, debido a su alta variabilidad.

Otra forma de representar los solapes entre categorías consiste en realizar un histograma de frecuencias de los ND que la componen. Por cuanto aquí sólo se cuenta con una muestra (los píxeles de las áreas de entrenamiento) y no con el total de esos ND, una alternativa para representar esta distribución de frecuencias parte de asumir que los ND en el seno de cada categoría se distribuyen normalmente. Esto permite estimar su distribución, a partir de conocer su media y desviación típica. De esta forma se construye la figura 7.40, que ofrece otra visión de los problemas de superposición entre clases, dibujando la elipse de la distribución normal para todas las clases que estamos considerando. La extensión de la elipse se ha fijado a 2 desviaciones típicas de la media. Este gráfico permite observar con mayor nitidez los posibles solapes entre categorías, y el gran efecto que tiene trabajar con categorías muy dispersas, ya que tenderán a «invadir» el rango espectral de otras. Eso es lo que ocurre con el suelo (la elipse mayor) que prácticamente ocupa todo el espacio de variación de la clase urbano, y, en menor medida, el correspondiente al matorral. En el extremo opuesto estaría el agua, que no muestra confusión con ninguna categoría.

Junto a los procedimientos gráficos existen algunos criterios cuantitativos que permiten evaluar numéricamente la posibilidad de discriminar las distintas categorías. El más sencillo consiste en calcular la distancia normalizada entre dos categorías ($dn_{A,B}$) (Swain y Davis, 1978):

$$dn_{A,B} = \frac{\left|\overline{ND}_A - \overline{ND}_B\right|}{s_A + s_B} \qquad [7.30]$$





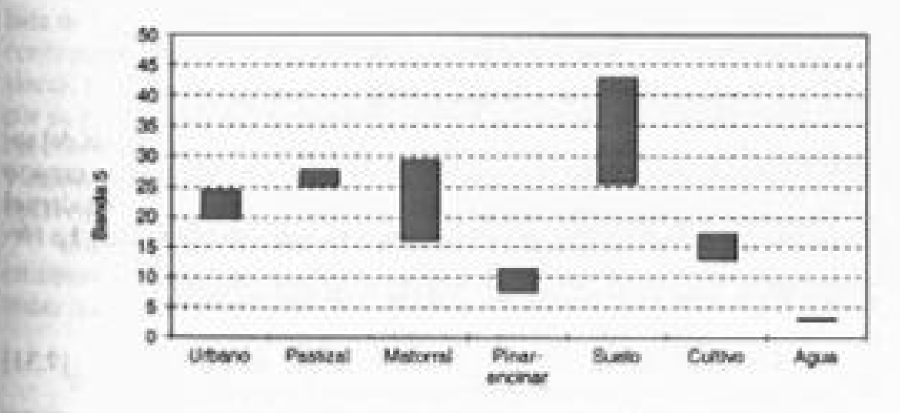


FIG. 7.39. *Diagrama de solape espectral entre cubiertas.*

calculada como la diferencia absoluta entre las medias de dos categorías (*A* y *B*), en proporción a la suma de sus desviaciones típicas. Este cálculo se aplica a cada par de bandas que intervienen en la clasificación, promediándose su valor para obtener una matriz de separabilidad.

Un poco más compleja, y también más versátil es la divergencia estadística (Swain y Davis, 1978; Thomas *et al.*, 1987*a*). Parte de asumir que los ND en una cate-

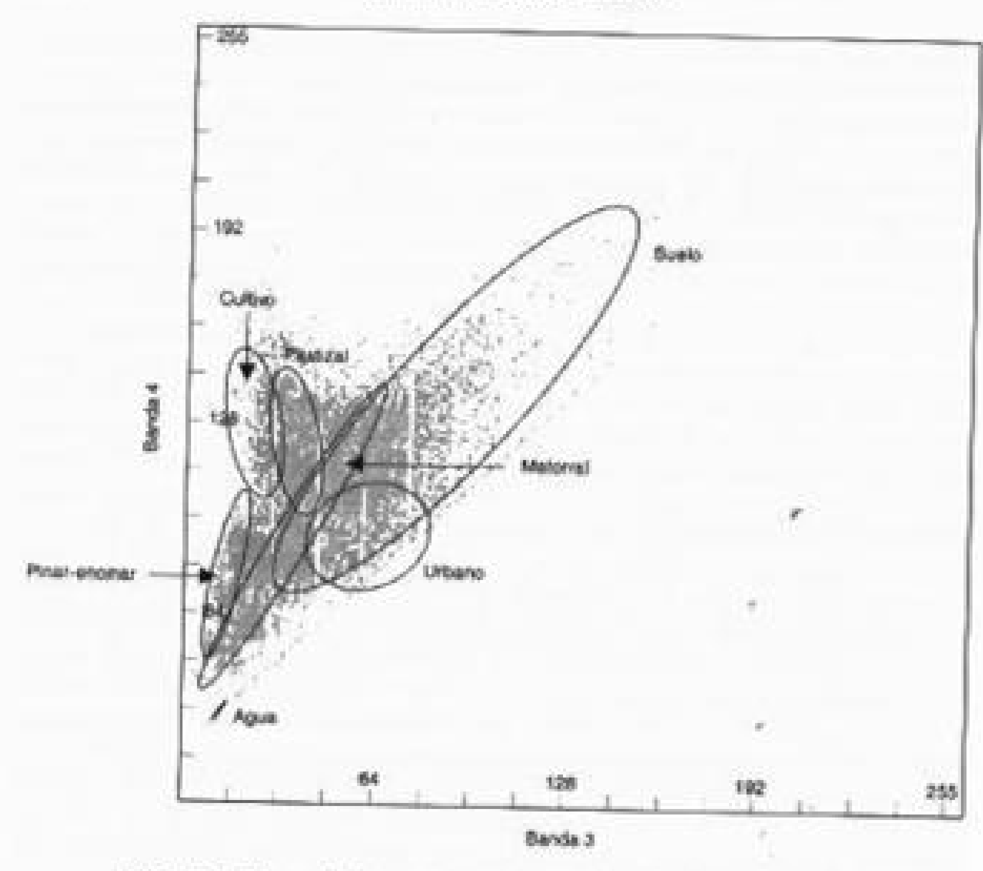


FIG. 7.40. *Elipses de dispersión espectral de las categorías seleccionadas para las bandas 3 y 4.*

goría se distribuyen normalmente, considerando la separabilidad como medida del solape entre categorías vecinas. Por cuanto se trata de calcular ese valor para un espacio multivariado (tantas variables como bandas intervienen en el proceso), se considera el vector de medias y la matriz de varianza-covarianza entre pares de categorías. La fórmula de cálculo se sintetiza de la forma siguiente:

$$Div_{AB} = 0,5\ Tr\{(V_A - V_B)(V_B^{-1} - V_A^{-1})\} + 0,5\ Tr\{(V_A^{-1} - V_B^{-1})(M_A - M_B)(M_A - M_B)^T\} \quad [7.31]$$

donde Div_{AB} indica la medida de la divergencia entre las categorías *A* y *B*; *Tr* se refiere a la traza o suma de los elementos de la diagonal de la matriz indicada [ ]; V_A y V_B son las matrices de varianza-covarianza de las categorías *A* y *B*; M_A y M_B son los vectores de medias correspondientes a las mismas categorías y bandas, y *T* indica la matriz traspuesta de la indicada entre paréntesis. Cuanto mayor sea el valor de la divergencia, mayor también la separabilidad entre clases, basada, lógicamente, sobre las bandas que se han considerado en su cálculo.

El problema fundamental de esta medida es que no se satura. Si se pretende relacionar la divergencia con la exactitud de la posterior clasificación, esto implica que la exactitud aumentaría constantemente al aumentar el número de bandas utilizadas para clasificar, lo cual no es muy realista. Por esta razón se recomienda acotar este valor en unos márgenes conocidos, definiéndose la divergencia transformada como (Kumar y Silva, 1977):

$$DT_{AB} = c(1 - \exp(-Div_{AB}/8)) \quad [7.32]$$

donde *c* indica el valor máximo de la divergencia, señalándose habitualmente un valor de 2.000, aunque algunos autores recomiendan utilizar un valor de 100 (Mather, 1998), para que los resultados puedan interpretarse como porcentajes.

La divergencia también se ha empleado como medida para seleccionar el conjunto de bandas que proporciona la mejor separación entre clases. En este sentido se calcula un valor promedio de divergencia, de acuerdo a Richards y Xia (1999):

$$\overline{div} = \sum_{i=1,m} \sum_{j=1,m} p(w_i)p(w_j)Div_{i,j} \quad [7.33]$$

donde $p(w_i)$ y $p(w_j)$ indican las probabilidades *a priori* de las clases *i* y *j*, *m* el número de clases, y $Div_{i,j}$ es el valor de la divergencia entre esas clases. La divergencia promedio se calcula para cualquier combinación de *m* bandas, siendo la combinación ideal la que maximiza el valor global de separación entre clases (Jensen, 1996, pp. 220-224). Además de la divergencia, se han propuesto otras medidas de separabilidad, como la distancia de *Bhattacharyya* o de *Mahalanobis* (Thomas *et al.*, 1987*b*).

La tabla 7.8 incluye el cálculo de la divergencia transformada (en este caso, escalada de 0 a 2) para las clases seleccionadas en nuestro ejemplo. Esta tabla nos permite confirmar las valoraciones previamente efectuadas sobre posibles confusiones entre clases. La clase más nítida es el agua, fácilmente separable del resto de las cubiertas, por su peculiar comportamiento espectral. Los suelos descubiertos ofrecen una notable confusión con la clase urbana, como ya comentamos en los gráficos de dispersión. También se observan problemas entre las clases matorral-urbano y pinar-encinar con cultivos.

Como antes indicamos, la divergencia también puede utilizarse para indicar la combinación idónea de bandas para la clasificación. En nuestro caso se calculó para todas las combinaciones de una, dos, tres y cuatro bandas, utilizando como bandas

TABLA 7.8. *Divergencia transformada entre las categorías de la imagen Torre100*

	Urbano	*Pastizal*	*Matorral*	*Pinar-encinar*	*Agua*	*Suelo*
Pastizal	2.000					
Matorral	1.998	1.999				
Pinar-encinar	2.000	2.000	2.000			
Agua	2.000	2.000	2.000	2.000		
Suelo	1.942	2.000	1.999	2.000	2.000	
Cultivo	2.000	2.000	2.000	1.993	2.000	2.000

de entrada las corregidas de reflectividad por el método de Chávez, como estamos haciendo en este epígrafe. La primera banda seleccionada por este método es la ETM-5 (SWIR), que ofrece la mayor divergencia promedio a las categorías que hemos seleccionado. Las dos bandas más discriminantes serían la 5 y la 3 (R, SWIR); mientras se seleccionan la 2, 4 y 5 (R, IRC y SWIR) para el caso de tres bandas. Éste sería el espacio ideal de separación considerando las características espectrales del sensor ETM+.

Como principal conclusión de este epígrafe, parece deducirse que el análisis de las estadísticas de entrenamiento resulta muy conveniente para reflexionar sobre la conveniencia de la leyenda empleada, del tipo de información disponible, o del método emprendido para conseguir los resultados deseados. Salvado este análisis, puede iniciarse la fase de clasificación propiamente dicha, en la que no deben producirse resultados muy distintos a los deducidos a partir de este previo estudio.

2.3. Fase de asignación

En esta fase se trata de adscribir cada uno de los píxeles de la imagen a una de las clases previamente seleccionadas. Esta asignación se realiza en función de los ND de cada píxel, para cada una de las bandas que intervienen en el proceso. Fruto de esta fase será una nueva imagen, cuyos ND expresen la categoría temática a la que se ha adscrito cada uno de los píxeles de la imagen original.

En este capítulo se tratan los criterios más empleados para realizar este proceso, en el contexto de las aplicaciones de la teledetección. Desde un punto de vista estadístico, todos ellos definen un área de dominio, en torno al centro de cada categoría a discriminar, mediante un conjunto de funciones discriminantes. Estas ecuaciones pueden considerarse, por tanto, como las fronteras que definen cada categoría. El píxel será asignado a una clase *i*, si sus ND se encuentran dentro del área de dominio señalado para dicha clase.

Los criterios más comunes para establecer estas fronteras estadísticas entre clases son: 1) mínima distancia, por el cual el píxel se asigna a la clase más cercana; 2) paralelepípedos, que permite señalar al usuario unos umbrales de dispersión asociados a cada clase, y 3) máxima probabilidad, en donde el píxel se asigna a aquella clase con la que posee mayor probabilidad de pertenencia. Frecuentemente se suelen agrupar en métodos no paramétricos, los dos primeros, y paramétricos, el último, en razón de si asumen o no que los ND en cada categoría se distribuyen normalmente. A continuación se describen, con más detalle, cada uno de estos criterios.

2.3.1. *Clasificador de mínima distancia*

El criterio más sencillo para asignar un píxel a una de las categorías consiste en incluirlo en la más cercana; esto es, en aquella que minimice la distancia entre ese píxel y el centroide de clase. Lógicamente, no se trata de una distancia geográfica, sino espectral, consecuencia de comparar los ND de cada píxel con los del centro de las distintas categorías, para todas las bandas que intervienen en el análisis (fig. 7.41).

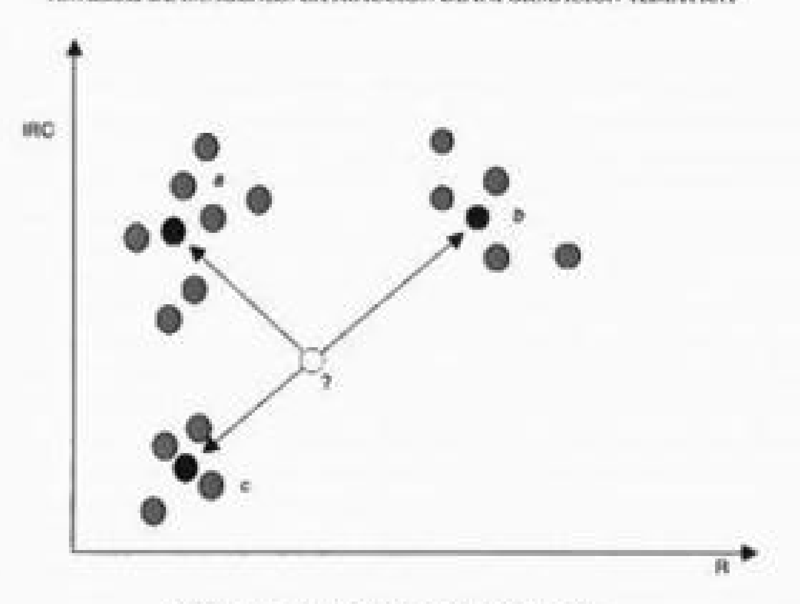


FIG. 7.41. *Algoritmo de mínima distancia.*

Pueden considerarse varias formas de medir esa distancia espectral entre píxeles y clases. La más empleada, en este sentido, es la distancia euclidiana:

$$d_{x,A} = \sqrt{\sum_{i=1,m} (ND_{x,i} - \overline{ND}_{A,i})^2} \qquad [7.34]$$

donde $d_{x,A}$ es la medida de la distancia entre el píxel *x* y la categoría *A*; $ND_{x,i}$ el valor correspondiente al píxel a clasificar en la banda *i*, y $\overline{ND}_{A,i}$ el valor medio de esa categoría en la misma banda. Tras calcular esta medida para todas las categorías, puede obtenerse el valor $d_{x,A}$ más pequeño, asignando el píxel *x* a esa categoría. Como se trata de realizar comparaciones entre distancias, la fórmula anterior puede simplificarse eliminando la raíz cuadrada, ya que si un píxel es más cercano a una categoría por la distancia lineal (hipotenusa de sus valores espectrales), también lo será por la suma de sus catetos.

Este algoritmo es bastante sencillo y rápido de ejecutar, y puede ofrecer buenos resultados cuando no se observe un gran solape entre categorías. Puesto que siempre existe una clase más cercana, no deja lugar a píxeles sin clasificar, incluso aunque éstos se alejen notablemente del centro de clase. Esto puede provocar errores de comisión importantes, sobre todo cuando no se incluya en la leyenda alguna categoría claramente presente en la imagen.

La distancia que calcula este algoritmo es lineal; además, no considera la dispersión de cada categoría o la correlación que exista entre las bandas. Tiende, por tanto, a delimitar grupos circulares de radio proporcional a la situación de cada categoría.

Algunos autores han propuesto modificaciones en el cálculo de la distancia, de tal forma que se considere la varianza de las clases (Lo *et al.*, 1986; Schowengerdt, 1983). De una u otra forma, el método de mínima distancia se ha empleado con frecuencia en

aplicaciones temáticas, especialmente cuando el área de estudio no presentaba una gran complejidad. Una excepción interesante a esta idea general es su aplicación exitosa a la cartografía de paisajes gallegos (López Vizoso, 1987).

2.3.2. *Clasificador de paralelepípedos*

En este método, el usuario fija un área de dominio para cada categoría, teniendo en cuenta sus valores de centralidad y dispersión. Posteriormente, un píxel es asignado a dicha clase si sus ND están dentro de ese área de dominio, en todas las bandas consideradas (fig. 7.42). Esquemáticamente, el píxel x será asignado a la clase A si sus ND en las distintas bandas ($ND_{x,i}$) están incluidos en el área de dominio de esa clase:

$$\overline{ND}_{A,i} - R_{A,i} \leq ND_{x,i} \leq \overline{ND}_{A,i} + R_{A,i} \qquad [7.35]$$

para todo i, variando de 1 hasta el número de bandas. $R_{A,i}$ indica el rango de dispersión señalado para la categoría A en cada banda i.

En suma, un píxel es asignado a una determinada clase si sus ND se encuentran a menos de una determinada distancia del centro de esa clase. Esa distancia se fija por el intérprete, aunque suele identificarse con la desviación típica, o con un múltiplo suyo. También pueden emplearse otros criterios como la desviación media, desviación intercuartílica o rango de la categoría. En cualquier caso, conviene considerar que cuanto mayor sea ese umbral, mayor también el número de píxeles incluidos en esa clase, pero también más grande el riesgo de confusiones con categorías vecinas. De igual forma, un valor pequeño garantiza mayor fiabilidad en las asignaciones, pero supone un mayor número de píxeles sin clasificar.

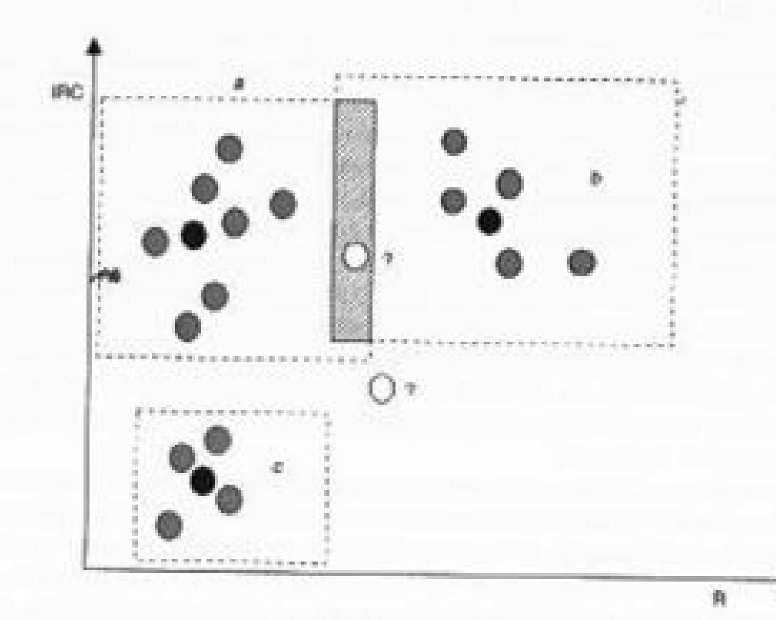


FIG. 7.42. *Clasificador de paralelepípedos.*

Este criterio de asignación tiende a delinear unos polígonos multidimensionales de lados paralelos, de ahí su nombre, en torno al centro de cada categoría. Es un algoritmo bastante rápido de ejecutar, puesto que sólo requiere operaciones lógicas sencillas (del tipo IF ... THEN...). Por esta rapidez, se ha utilizado con frecuencia como primer acercamiento a la variabilidad de las distintas categorías (Miller y Williams, 1978). Asimismo, se ha utilizado para lograr una primera estratificación de la imagen, aislando las categorías más singulares, para aplicar posteriormente otro criterio de asignación sobre los píxeles más problemáticos (Núñez *et al.*, 1983).

Los principales problemas de este método parten de su misma concepción. El diseño de áreas de dominio puede implicar, por un lado, que haya píxeles en zonas comunes a dos o más categorías, y, por otro, que algunos píxeles queden sin clasificar (fig. 7.42). Respecto al primer problema, el solape entre paralelepípedos supone que un píxel pueda asignarse a dos categorías. Si el programa no cuenta con otro criterio, lo incluirá en la primera que cumpla los requisitos marcados en [7.35]. En consecuencia, algo tan intrascendente como el orden en el que se produce la asignación tiene una importante repercusión sobre los resultados. Algunos autores han propuesto modificar el criterio de asignación para estas áreas en conflicto, bien introduciendo la regla de mínima distancia (Cosentino *et al.*, 1981; Mather, 1998), bien ajustando interactivamente las fronteras entre clases (Lillesand y Kiefer, 2000), bien creando clases mixtas.

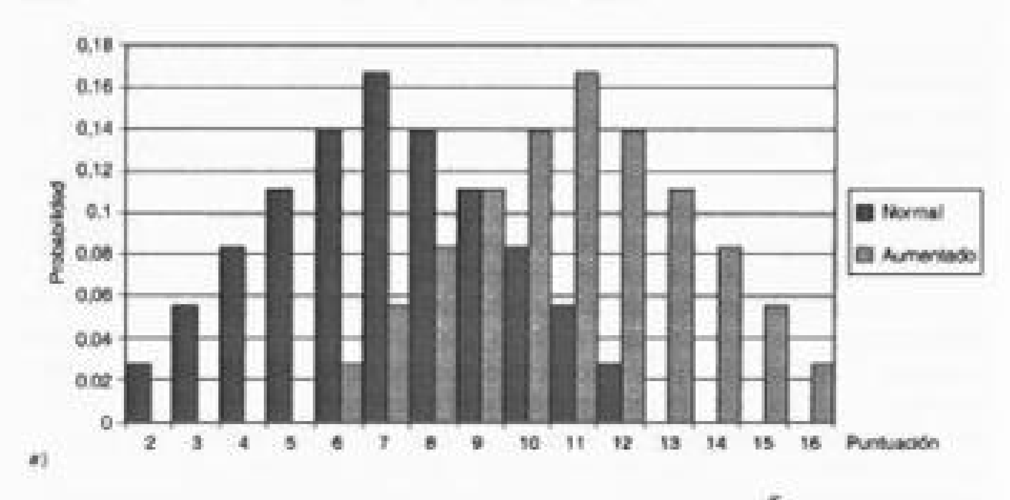
Respecto a los píxeles sin clasificar, la solución pasa por ampliar paulatinamente el rango de dispersión, estableciendo un equilibrio entre los píxeles no clasificados y los solapes entre clases vecinas. También conviene, en estos casos, repasar la definición espectral de las categorías, puesto que la presencia de píxeles sin asignación es indicio de clases espectrales mal definidas o no incluidas en la leyenda de trabajo.

2.3.3. *Clasificador de máxima probabilidad*

Este método considera que los ND en el seno de cada clase se ajustan a una distribución normal. Esto nos permite describir esa categoría por una función de probabilidad, a partir de su vector de medias y matriz de varianza-covarianza. En pocas palabras, esa función asemeja la distribución real de los ND en esa categoría, por lo que nos sirve para calcular la probabilidad de que un píxel (con un determinado ND) sea miembro de ella. El cálculo se realiza para todas las categorías que intervienen en la clasificación, asignando el píxel a aquella que maximice la función de probabilidad.

El clasificador de máxima probabilidad es el más complejo y el que demanda mayor volumen de cálculo. Sin embargo, es el más empleado en teledetección, por su robustez y por ajustarse con más rigor a la disposición original de los datos.

Para comprender mejor su funcionamiento basta poner un sencillo ejemplo ideado por Swain y Davis (1978). Supongamos que se cuenta con dos pares de dados, uno normal (caras numeradas de 1 a 6) y otro con un par de puntos adicionales en cada cara (numerados de 3 a 8). Conociendo el valor de una tirada, el problema sería estimar de cuál de los dos pares de dados procede. Un criterio razonable de asignación sería calcular la probabilidad de que esa tirada se haya realizado con los dados normales o con los modificados, asignando la tirada desconocida al par de dados más probable. Por ejemplo, si obtenemos un tirada de 7, la probabilidad de haber tirado con los dados



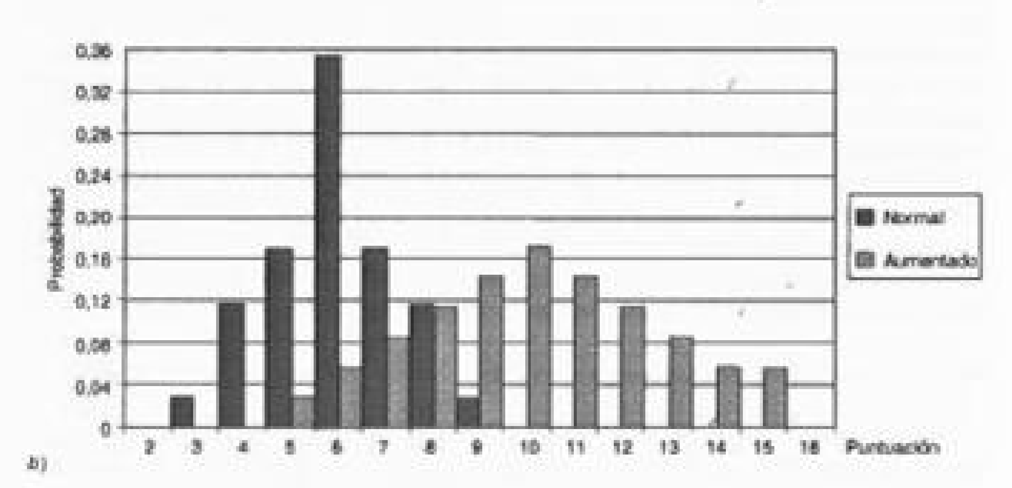


FIG. 7.43. *Fundamentos del algoritmo de máxima probabilidad.*

normales es 6/36 (6 casos favorables, frente a los 36 posibles).[6] Para los dados aumentados, la probabilidad es menor, 2/36,[7] por lo que la tirada se asigna al par de dados normal. El mismo criterio podría seguirse para decidir la asignación de cualquier otra puntuación. Basta construir las funciones de probabilidad asociadas con cada par de dados. Para el par normal tendríamos una distribución centrada en el valor 7 (máxima probabilidad), con un mínimo de 2 y un máximo de 12. Para el par modificado, el valor más probable se encontraría en 11, situándose la curva entre 6 y 16 (fig. 7.43*a*). A partir de esta gráfica se observa que la probabilidad de haber usado los dados normales es mayor que la de haber usado los aumentados si obtenemos una tirada inferior a 8, es

6. Podría haberse obtenido un 7 por las siguientes combinaciones de los dos dados: 1 y 6, 6 y 1, 2 y 5, 5 y 2, 3 y 4, y 4 y 3.

7. Sólo puede obtenerse un 7, en este caso, por combinación de 3 y 4 o 4 y 3.

menor si la tirada superó 10 y es idéntica si la tirada fue 9. En definitiva, la frontera para asignar la tirada a un par de dados u otro se establece en la intersección entre sus respectivas funciones de probabilidad.

Esto no significa, obviamente, que no pueda producirse una tirada mayor a 9 con el par de dados normal, ni inferior a 9 con el aumentado. En otras palabras, la regla no es completamente certera, pero sí bastante razonable. Sólo es plenamente fiable para valores superiores a 12 o inferiores a 6, puesto que ahí no existe solape entre categorías. En suma, si existe conflicto natural entre clases, no es posible separarlas con total fiabilidad. Los errores serán tanto mayores cuanto mayor sea el solape entre las funciones de probabilidad.

Extendiendo el ejemplo propuesto por Swain y Davis, supongamos que al par de dados normal le modificamos alguna cara, para que las puntuaciones vayan de dos a cinco, en lugar del 1 y el 6, repitiendo las puntuaciones 3 y 4. Esto no implicaría modificar el valor central de la distribución, que seguiría siendo 7. Sin embargo, sí cambia la anchura de la curva, las puntuaciones están más cercanas a la media, hay mayor homogeneidad. Eso conlleva que las asignaciones que se hagan a partir de la distribución de probabilidad serán más seguras. El punto de corte sigue estando en 9, pero a partir de ese valor la probabilidad de encontrar puntuaciones superiores con el par de dados normal se reduce drásticamente (fig. 7.43*b*). Esto implica que a mayor homogeneidad, o si se prefiere menor varianza, la discriminación de categorías resulta más certera.

El ejemplo puede aplicarse fácilmente al contexto de la clasificación digital. El par de dados a estimar puede sustituirse por las distintas categorías que quieren discriminarse, y las tiradas por los ND de los píxeles a clasificar. En el caso de los dados, podemos calcular *a priori* la probabilidad de pertenencia asociada con cada tirada, pues conocemos la distribución de todas las posibles tiradas. Para el caso de la clasificación de categorías temáticas es preciso estimar esa distribución de probabilidad para cada categoría, a partir de las medidas realizadas sobre las áreas de entrenamiento. Con este fin se considera que los ND en el seno de cada clase se distribuyen normalmente, por lo que basta conocer la media y la desviación típica de cada categoría para calcular la probabilidad asociada con un determinado ND. En el caso de trabajar con una sola banda podríamos calcular esa probabilidad de acuerdo a:

$$p(x / A) = \frac{1}{\sqrt{2\pi\sigma_A^2}} \exp\left\{-(ND_x - \overline{ND}_A)^2 / 2\sigma_A^2\right\} \qquad [7.36]$$

Esto es, la probabilidad de que un píxel x, definido por un determinado ND_x, pertenezca a la clase A, puede calcularse a partir de la media ($\overline{ND}_A$) y la varianza (σ_A^2) de esa clase. Una vez determinada la probabilidad de pertenencia al resto de las categorías que intervienen en la clasificación, ese píxel será asignado a la clase A, sólo si:

$$p(x / A) \geq p(x / B) \qquad [7.37]$$

para todo $A \neq B$, variando B desde 1 hasta c, siendo c el número de categorías.

Con el propósito de agilizar el cálculo, habitualmente se transforma la fórmula anterior en una función lineal, mediante el empleo de logaritmos (Schowengerdt, 1983):

$$\ln p(x/A) = -0{,}5\ln(2\pi) - 0{,}5\ln\sigma_A^2 - \left\{(ND_x - \overline{ND}_A)^2/2s_A^2\right\} \qquad [7.38]$$

La expresión puede simplificarse aún más si eliminamos el primer término (–0.5 ln (2π)), por cuanto nos interesa sólo un cálculo de la probabilidad relativo a las distintas clases, y ese valor es una constante para todas ellas. Por la misma razón, no resulta necesario reconvertir a antilogaritmos el valor calculado, ya que si el logaritmo de la probabilidad es mayor en una categoría que en otra, también lo será su antilogaritmo. Por último, el segundo término ($0{,}5\ln\sigma_A^2$) puede calcularse inicialmente para cada categoría, quedando así reducido el cálculo, para cada píxel, a la última expresión.

Volviendo al ejemplo anterior, podría también ocurrir que contáramos con dos pares de dados normales y sólo con uno aumentado. En este caso, no sólo tendremos que considerar el valor de la tirada para identificarla como perteneciente a uno u otro tipo de dados, sino también la probabilidad *a priori* de que aparezca una tirada de cada par de dados, en función de su número. En muchas aplicaciones de la teledetección también se produce este fenómeno. Algunas de las categorías cuentan con mayor extensión superficial, y, por tanto, presentan mayor probabilidad de albergar píxeles desconocidos. Al considerar la probabilidad *a priori* de cada categoría $p(A)$ se introduce un nuevo factor en el criterio de decisión arriba enunciado [7.37]. De esta forma, un píxel pertenece a la clase A si:

$$p(x/A)\,p(A) \geq p(x/B)\,p(B) \qquad [7.39]$$

para todo $A \neq B$, donde $p(x/A)$ indica la probabilidad de que un píxel x con un ND determinado pertenezca a la clase A, y $p(A)$ la probabilidad *a priori* de que un píxel cualquiera se incluya en esa clase.

La figura 7.44 expresa gráficamente el efecto de introducir esta opción. El punto de corte entre las distribuciones de probabilidad se desplaza hacia un lado u otro del original, en función del valor de la probabilidad *a priori*. Recuérdese que la intersección entre curvas marca la frontera en el área asignada a cada categoría, por lo que este factor puede modificar significativamente los resultados.

Con ser de gran interés, el empleo de este parámetro resulta bastante complejo, especialmente para establecer un criterio riguroso que permita estimar los valores de probabilidad *a priori* para cada clase. Un posible criterio sería conceder a cada categoría una probabilidad equivalente a la superficie que ocupa en la zona de estudio. Esto requiere, naturalmente, contar con un inventario previo, que raras veces está disponible. Indirectamente, sin embargo, puede calcularse la importancia superficial de cada clase mediante trabajos de campo, datos auxiliares o empleando los resultados de una clasificación previa. Por último, también puede optarse por obviar este criterio, simplemente otorgando la misma probabilidad *a priori* a todas las categorías.

El interés de ponderar la probabilidad de cada clase se ha puesto en evidencia por distintos autores (Strahler, 1980). En aquellas ocasiones en las que se cuenta con un criterio sólido para estimar esas probabilidades se ha comprobado que mejoran la asignación significativamente (Mergerson, 1981; Valerio y Ledesma, 1981).

Hasta el momento hemos analizado el criterio de máxima probabilidad para el caso de una sola banda. Lo habitual será, no obstante, que se empleen varias bandas

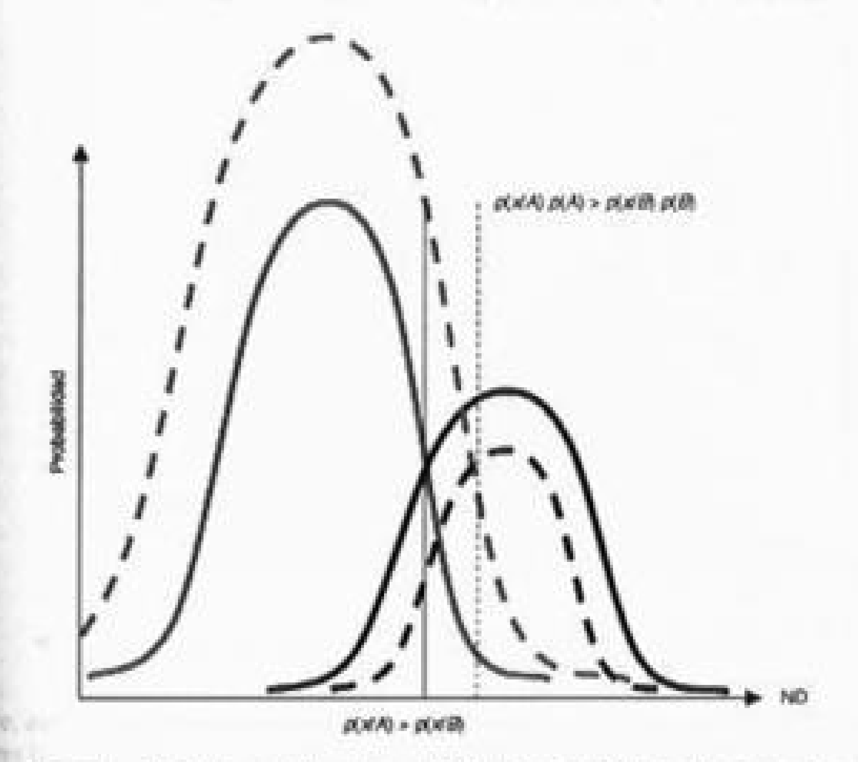


FIG. 7.44. *Efecto de considerar la probabilidad a priori. En línea discontinua las nuevas funciones de probabilidad y la intersección entre las dos categorías.*

para la clasificación, por lo que resulta preciso extender a varias dimensiones lo hasta aquí comentado. Para el caso de dos bandas, los límites de las categorías tienen una forma elipsoidal (fig. 7.45). Cada una de estas elipses define un determinado nivel de probabilidad asociado a una categoría. Cuanto mayores sean las zonas de solape entre ellas, tanto mayor el riesgo de confusión mutua.

Con más de dos dimensiones no es posible representar gráficamente este criterio de clasificación. Basta extender la fórmula de la probabilidad normal arriba apuntada:

$$p(x/A) = (2\pi)^{-m/2}\,|V_A|^{-0{,}5}\exp\{-0{,}5\,(M_x - M_A)^T\,V_A^{-1}\,(M_x - M_A)\} \qquad [7.40]$$

donde m indica el número de bandas, $|V_A|$ la determinante de la matriz de varianza-covarianza para la clase A; M_x el vector de ND asociado con el píxel x; M_A, el vector de ND medios de la categoría A, y los superíndices T y -1, la traspuesta y la inversa de las matrices a las que afectan, respectivamente. Esta fórmula también puede simplificarse mediante el uso de logaritmos (Schowengerdt, 1983):

$$\ln p(x/A) = (-0{,}5\ln V_A) - (0{,}5\,(M_x - M_A)^T\,V_A^{-1}\,(M_x - M_A) \qquad [7.41]$$

una vez suprimidos los términos constantes de la fórmula anterior.

Pese a estas simplificaciones, este método de asignación exige un gran volumen

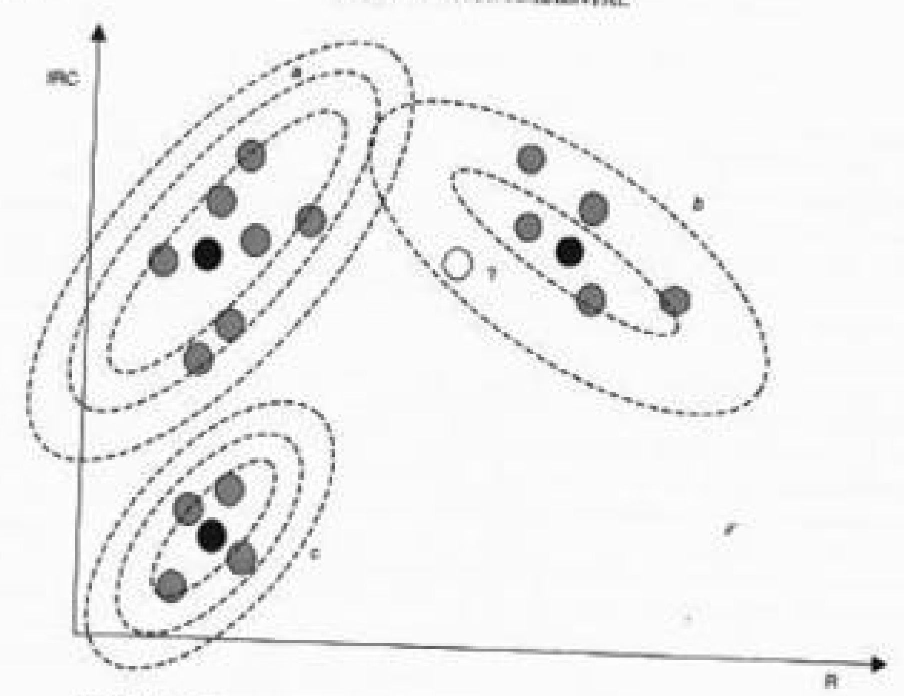


FIG. 7.45. *Extensión a dos bandas del algoritmo de máxima probabilidad.*

de operaciones. Con el fin de reducir el tiempo invertido en el proceso, algunos autores han propuesto métodos alternativos para el cálculo de la probabilidad. Las tablas de probabilidad, similares a las CLUT vistas anteriormente (cap. 6.5), parecen ser la solución más ventajosa a este respecto (Mather, 1998, pp. 304-307). Gracias a la mayor potencia de cálculo que facilitan los ordenadores ahora disponibles, este tipo de clasificación ya no implica una inversión de tiempo considerable.

Una vez que se culmine la asignación de los píxeles de la imagen es posible establecer unos umbrales de probabilidad para cada categoría, de tal forma que se rechacen aquellos píxeles con una probabilidad de pertenencia muy baja (fig. 7.46). Este proceso, posterior a la clasificación propiamente dicha, pretende evitar aquellos píxeles con un grado de asociación muy bajo, reduciendo así los errores de comisión debidos a una mala definición espectral de algunas categorías.

Esto llevará consigo la aparición de píxeles no clasificados. Si su número es considerable, convendrá retornar a la fase de entrenamiento, con objeto de deducir nuevas categorías o perfeccionar la definición de las ya existentes. En la figura 7.47 se incluye un ejemplo de la aplicación de este criterio, en este caso a la imagen Barrax99. Se ha utilizado un criterio bastante exigente de probabilidad *a posteriori*, que elimina la asignación a los píxeles con menos del 95 % de probabilidad de pertenencia. A consecuencia, la mayor parte de la imagen aparece como no clasificada, pero las zonas sí asignadas identifican las más similares a las características de las áreas que se utilizaron para el entrenamiento.

El criterio de máxima probabilidad asume que las categorías presentan una distribución normal, requisito que ha sido comprobado en numerosos estudios. No obstante, aun en el caso de que las bandas de entrada no cumplan este criterio, algunos autores han mostrado que los resultados siguen siendo bastante consistentes (Swain y Davis, 1978).

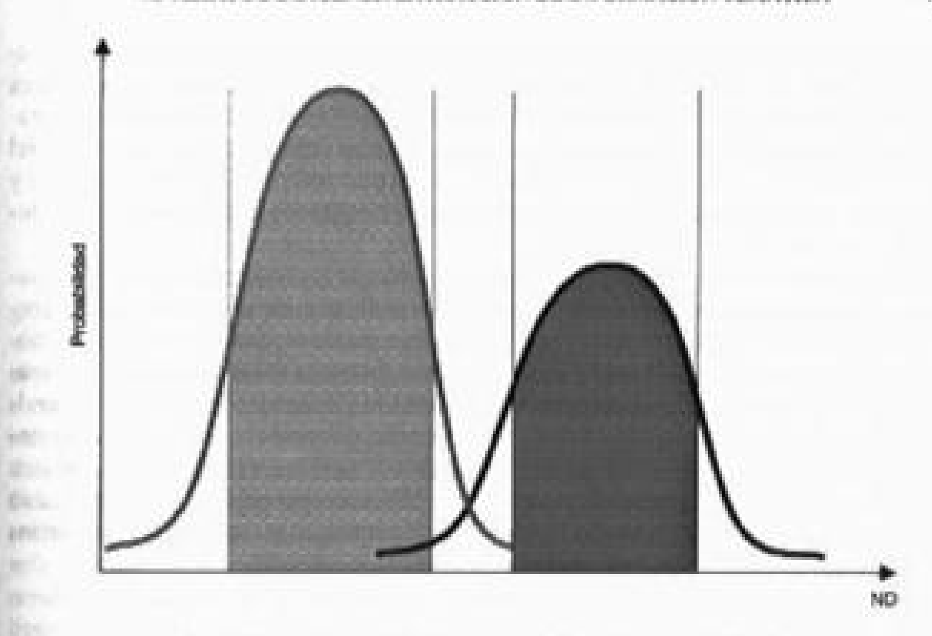


FIG. 7.46. *Efecto de considerar la probabilidad* a posteriori.

Para la imagen Torrel00, la aplicación del criterio de máxima probabilidad permitió generar una clasificación bastante atinada (fig. 16*). Las principales confusiones se observaron entre las categorías urbanas y los suelos descubiertos, si bien las primeras se discriminan razonablemente bien, tanto en los cascos de los municipios, como en sus áreas residenciales. Los matorrales y encinares tienen una clara yuxtaposición, mientras la categoría pinar-encinar en realidad sólo se refiere a los pinares de

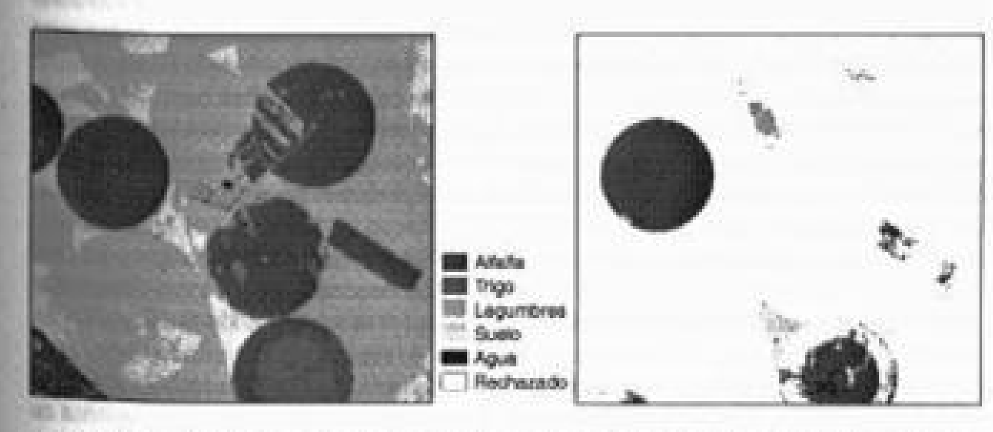


FIG. 7.47. *Clasificación de cultivos en la imagen Barrax99: original y después de rechazar los píxeles < 95 % de probabilidad.*

P. sylvestris situados en las zonas de mayor relieve. Los cultivos se ciñen exclusivamente al valle del Jarama, en el borde oriental de la imagen, mientras los pastizales ocupan la mayor parte de los fondos de valle en los municipios de Soto del Real, Miraflores y Guadalix. Por su parte, los matorrales-encinares se localizan en las laderas del cerro de San Pedro, en el centro de la imagen y en el piso inferior de la sierra, al norte y oeste de la zona de estudio. En este último sector se confunden en ocasiones con caducifolios que aún no han echado la hoja.

Comparando estos resultados con los generados de la clasificación no supervisada, a partir del algoritmo ISODATA (con 18 clases finales, de un máximo de 20 previamente fijado) se pudo observar que se separaban mejor algunas clases informacionales, como las correspondientes a pinar y encinar, bastante solapadas en la clasificación de máxima probabilidad, mientras el matorral se ciñó mejor a las áreas que realmente ocupaba. La categoría urbana, por el contrario, apareció un poco más difuminada en la clasificación no supervisada, confundida con suelos en el caso de los núcleos más densos. No todas las áreas residenciales-ajardinadas aparecían, pero sí una buena parte de ellas. También se realizó una buena discriminación de los suelos descubiertos y del agua.

2.3.4. *Clasificadores en árbol*

Si bien el clasificador de máxima probabilidad es el más ampliamente utilizado en clasificación digital de imágenes, sus limitaciones en cuanto al cálculo y la exigencia de contar con distribuciones normales hacen que se hayan buscado criterios alternativos, menos sensibles a esos requisitos.

Uno de los métodos más sencillos, pero también más eficientes de clasificación alternativa es el denominado clasificador en árbol *(decision tree classifier)*. La idea de fondo consiste en discriminar secuencialmente cada una de las categorías, basándose, bien en valores espectrales de la imagen, bien en variables texturales, temporales o en información auxiliar (suelos, MDE, etc.). Para cada clase se establecen unas reglas dicotómicas de interpretación, que permiten concentrar la discriminación de cada clase a partir de las variables en que mejor se discrimina, en lugar de utilizar todas indistintamente. Por ejemplo, puede reconocerse las láminas de agua por un ND inferior a un cierto umbral en la banda IRC, o la vegetación por una combinación de cierto umbral en el visible e infrarrojo cercano. En su origen, estos criterios estaban basados exclusivamente sobre los datos espectrales de la imagen, pero en los últimos años se ha promovido el empleo de este tipo de criterios de decisión considerando igualmente variables auxiliares, como mapas de suelos o modelos digitales de elevación (Friedl y Brodley, 1997; Hansen *et al.*, 1996).

Bajo ese punto de vista, el clasificador en árbol puede considerarse como un sencillo ejemplo de sistema experto (Skidmore, 1989), tan extendido en los últimos años en el marco de las denominadas técnicas de inteligencia artificial. En pocas palabras, un sistema experto está formado por un conjunto de reglas que permiten al algoritmo tomar una serie de decisiones en función de los valores que observa en la imagen y/o en información auxiliar de la misma zona. Esas reglas se introducen al algoritmo en forma de operadores lógicos condicionales, del tipo IF... THEN..., que intentan simular la toma de decisiones que realiza un intérprete (Richards, 1993, cap. 12). Por ejemplo, podríamos distinguir la vegetación forestal de la herbácea a parte de asociar criterios de tono y textura, utilizando una regla del tipo siguiente:

IF $ND_{IRC} / ND_R > 2$ AND *Textura* = Rugosa THEN *Bosque*

IF $ND_{IRC} / ND_R > 2$ AND *Textura* = Lisa THEN *Prados*

El primer término lo podría tomar de una imagen óptica y la textura de una imagen radar de la misma zona. De forma similar se pueden introducir variables no obtenidas por teledetección, como cartografía temática, límites administrativos o modelos digitales de elevación. El establecimiento de los criterios de decisión se realiza por un experto en el reconocimiento de cada categoría de interés, que conozca sus condiciones ambientales para la zona en la que se trabaja. Por ejemplo, para el reconocimiento de una especie forestal serían relevantes el calendario fenológico, la situación topográfica, el tipo de litología asociado, o la rugosidad. Con este enfoque, Skidmore (1989) realizó un inventario de eucaliptos en Australia, a partir de imágenes de satélite e información auxiliar. Este autor observó una mejora significativa en la clasificación, mediante el empleo de una tabla de probabilidades asociada a la ocurrencia del eucalipto en distintas variables auxiliares. También podrían incorporarse criterios temporales o espaciales, como sería la probabilidad de que un cierto cultivo suceda a otro o esté próximo a otro (Middelkoop y Janssen, 1991).

Los clasificadores en árbol se han utilizado en los últimos años con cierto éxito, tanto en la cartografía de especies forestales (Saura y San Miguel, 2001), como para asignar tipos de vegetación y cobertura del suelo, con especial relieve en aplicaciones de ámbito global (Friedl y Brodley, 1997; Friedl *et al.*, 1999).

Naturalmente, los sistemas expertos también pueden aplicarse a otras operaciones de análisis de la imagen, como son los realces o las correcciones radiométricas y geométricas (Schowengerdt y Wang, 1989).

Un sencillo ejemplo de clasificación en árbol sería el incluido en la figura 7.48. El criterio de decisión se basa en unas hipotéticas estadísticas de entrenamiento para una serie de clases de cobertura del suelo (tabla 7.9). En este caso, el análisis se realiza sobre cuatro bandas espectrales: V, R, IRC y SWIR, a las que se ha añadido información altitudinal extraída de un MDE. A partir de estos valores puede diseñarse un gráfico de dispersión espectral, considerando el rango como la media ± 2 desviaciones típicas. Con ayuda de este gráfico podemos diseñar un árbol de decisiones que nos permita separar las cinco categorías. El primer paso consiste en separar los píxeles pertenecientes a la categoría más fácilmente discriminable, el agua. Para ello se emplea el IRC, utilizando un umbral máximo de reflectividad del 10 %. Por tanto, los píxeles con una $\rho \leq 10$ en esa banda serán etiquetados como clase agua y extraídos de la imagen para evitar que intervengan en pasos sucesivos.

Posteriormente se emplea la banda V para discriminar las clases regadío y caducifolios del resto, indicando como valor límite la ρ del 30 %. Con las categorías urbano y cereal es preciso realizar el ajuste en dos bandas, puesto que existe un cierto solape en todas ellas. Sin embargo, la separación es mayor en la banda del SWIR, señalando sobre ella un umbral del 40 % de ρ para la discriminación, completándolo con otro umbral del 30 % en la banda R. Finalmente, entre las clases caducifolios y regadío, bas-

TABLA 7.9. *Medidas estadísticas para distintas cubiertas (reflectividad · 100)*

	Verde		Rojo		IRC		SWIR	
	X_{med}	D. T.	X_{med}	D. T.	X_{med}	D. T.	X_{med}	D. T.
Agua	13	3	12	2	8	2	3	2
Cereal	35	5	28	8	50	12	42	8
Regadío	14	5	19	4	60	10	14	2
Caducifolios	16	4	21	6	54	12	18	3
Urbano	42	7	36	5	48	10	34	7

tante mezcladas espectralmente, utilizamos un criterio basado en la altitud: asumiendo que en la zona sólo se dan cultivos en regadío por debajo de 800 metros, utilizamos el modelo digital de elevaciones para establecer esta distinción.

Los problemas de clasificación reales son más complejos, pero también pueden enriquecerse notablemente las reglas de decisión. Una vez ajustadas adecuadamente, resulta un criterio muy rápido de clasificación, y permite introducir información auxi-

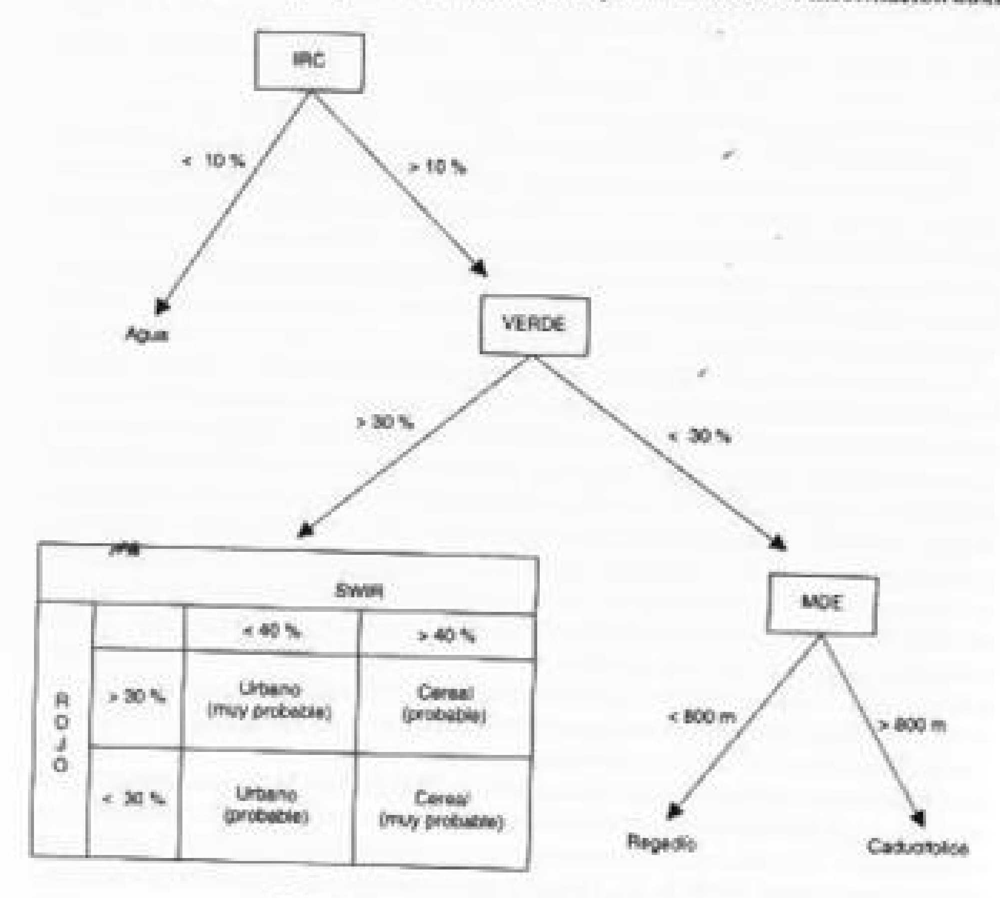


FIG. 7.48. *Ejemplo de clasificación en árbol.*

liar que resulta ajena a los clasificadores estadísticos convencionales (Friedl y Brodley, 1997). Un ejemplo más realista de clasificación en árbol es el algoritmo de detección de nubes propuesto por Saunders y Kriebel (1988), que tuvimos ocasión de analizar en el anterior capítulo, o los diversos algoritmos propuestos para detección de incendios activos (Martín *et al.*, 1999).

2.3.5. *Clasificadores basados en el contexto espacial*

A lo largo de esta obra hemos visto en diversas secciones que los rasgos espectrales de una determinada cubierta pueden presentar notables afinidades con otras, aunque posea componentes distintos. La aparente paradoja se relaciona con varios factores:

1. Resolución espectral del sensor, bien por contar con pocas bandas espectrales, bien por ser éstas excesivamente anchas para detectar variaciones en rangos muy específicos de variación espectral.
2. Resolución espacial, que da lugar a la aparición de señales mixtas entre dos o más cubiertas.
3. Resolución temporal, que conlleva la confusión de ciertas cubiertas en momentos específicos de su desarrollo fenológico.

En consecuencia, para discriminar dos cubiertas puede ser necesario acudir a criterios no estrictamente espectrales, como serían los derivados de la variación espacial de cada píxel, en una cierta área de vecindad, o su situación respecto al resto de los píxeles que forman la imagen. Hasta aquí hemos analizado criterios de clasificación basados exclusivamente en los ND de cada píxel; en ocasiones será preciso incorporar otros criterios de identificación, como son la textura o el contexto, afines a las relaciones espaciales entre los píxeles de la imagen, de modo similar a los utilizados en análisis visual (cap. 5).

La distinción entre los criterios de textura y contexto hace referencia al área que se considera en la medición de las relaciones espaciales (Gurney y Townshend, 1983). El primer concepto se relaciona con la variación espacial dentro de grupos contiguos de píxeles. El segundo iría encaminado a medir las relaciones espaciales de cada píxel con el resto de la escena. Por simplificar las cosas incluiremos ambos en el mismo epígrafe, ya que los dos están encaminados a aportar criterios espaciales a la clasificación de imágenes.

Hasta el momento, los métodos para introducir el contexto espacial en la interpretación digital pueden agruparse en función de la fase de la clasificación en la que intervienen. Así, podemos distinguir entre aquellos que generan bandas texturales previas a la clasificación, los que emplean el contexto durante la clasificación y los que lo consideran después de la asignación, con objeto de refinar los resultados.

Más adelante tendremos ocasión de comentar algunas técnicas para obtener información textural de la imagen (4.2). Por el momento, baste decir que se trata de métodos que generan una nueva imagen en la que el ND mide el grado de contraste espacial con los píxeles vecinos (habitualmente con los 8 circundantes). Estas medidas de textura se han desarrollado especialmente en el campo de las aplicaciones urbanas, ya que la clasificación de estas zonas resulta muy problemática por la gran variedad espectral de las superficies que las componen. Entre los criterios más interesantes está el propuesto por

Gong y Howarth (1990*a*). Estos autores pretendían discriminar áreas urbanas y rurales en la frontera rur-urbana de una ciudad canadiense. Para ello incorporaron a la clasificación una imagen de «densidad de bordes», obtenida a partir del siguiente proceso: 1) aplicar un filtro laplaciano a la banda 1 de una imagen SPOT-XS, 2) segmentar el resultado para dejar únicamente las fronteras entre cubiertas, 3) hallar la densidad de bordes a través de una ventana móvil (número de píxeles fronterizos dividido por número de píxeles en la ventana; en este caso de 25 × 25 píxeles), y 4) incorporar esa banda textural a la clasificación multibanda. Esa incorporación mejoró significativamente los resultados al reducir la confusión entre clases rurales y urbanas de similares características espectrales (p. ej., cultivos y jardines). También resulta de gran interés el clasificador de contexto propuesto por Moller-Jensen (1990), que parte de delimitar polígonos en una zona urbana mediante la localización automática de segmentos lineales (calles anchas o ríos). Los segmentos se clasifican de acuerdo a sus ND medios, así como a medidas de textura, contigüidad y distancia al centro de la ciudad.

El análisis del contexto previo a la clasificación puede abordarse también en la fase de entrenamiento. Un enfoque original, en este sentido, fue el denominado clasificador ECHO (*Extraction and Classification of Homogeneous Objects*), propuesto en la primera etapa de la interpretación digital de imágenes (Ketting y Landgrebe, 1975), pero que se ha enfatizado mucho en los últimos años, ante el interés por la generación de clasificaciones más robustas especialmente.

Este criterio proponía clasificar una imagen, no a partir de píxeles, sino de áreas compuestas por píxeles de similares características. En resumen, se trataba previamente de extraer objetos homogéneos, para luego ser asignados a las categorías de interés para el usuario. La delimitación de esas áreas homogéneas se basaba en criterios de similitud espectral y contigüidad. Tras localizar un pequeño grupo de píxeles con ND similares, el algoritmo iba incorporando progresivamente píxeles vecinos, siempre que estuvieran dentro de un criterio de homogeneidad señalado por el usuario (por ejemplo, a menos de una determinada distancia espectral). Cuando los píxeles vecinos no eran suficientemente homogéneos se identificaba una frontera o un área pequeña de distinta ocupación (isla). Estas zonas se clasificaban posteriormente de acuerdo a los criterios tradicionales, antes comentados. El proceso de crecimiento de las áreas continuaba hasta que se encontraban píxeles muy contrastados, con lo que el proceso se detenía. En este punto, la imagen aparecía segmentada en áreas homogéneas, aunque éstas aún no se hubieran asignado a ninguna categoría temática. La asignación se realizaba posteriormente calculando las estadísticas elementales de los píxeles incluidos en cada área, y aplicando sobre ellas uno de los criterios de asignación antes comentados. En ese punto, no eran asignados píxeles individuales, sino las áreas completas, por lo que la posibilidad de discontinuidad espacial de los resultados tendía a reducirse considerablemente (Campbell, 1996; Hoffer y Swain, 1980).

El planteamiento pionero del clasificador ECHO se ha subrayado bastante en los últimos años, estudiándose las ventajas e inconvenientes que presenta la clasificación sobre píxeles (*per pixel classifiers*) o sobre polígonos (*per field classifiers*: Aplin *et al.*, 1999). Como ya hemos indicado, los clasificadores más tradicionales realizan la asignación de cada píxel por separado, en función de los ND que presenta en las distintas bandas. Los clasificadores contextuales prefieren categorizar aglomerados espaciales de píxeles, que previamente se han obtenido aplicando algún algoritmo de con-

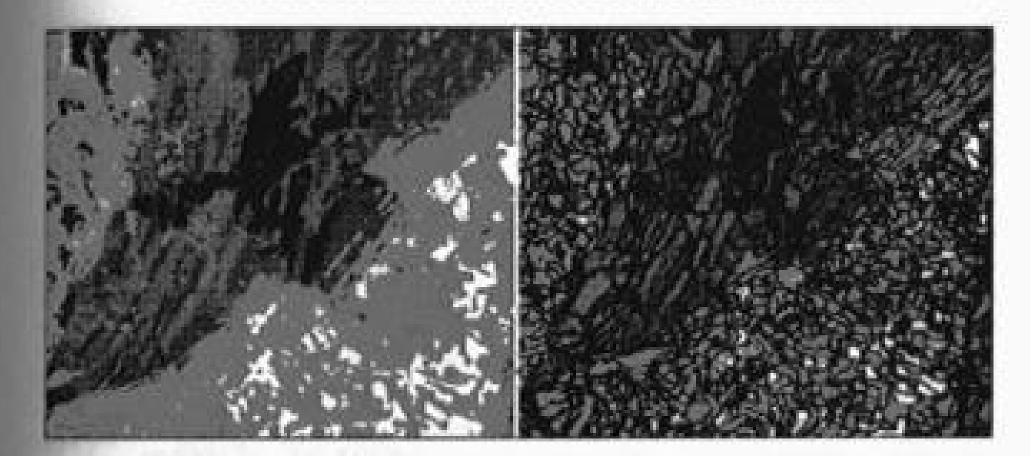


FIG. 7.49. *Segmentación espectro-espacial de una imagen de Torrelaguna.*

texto espacial. Esto implica, en pocas palabras, cambiar la unidad de análisis, del píxel a polígono, mediante una segmentación espectro-espacial de la imagen, que tiende a definir objetos espectralmente similares y contiguos. El proceso es especialmente idóneo para imágenes de alta resolución espacial, que de otro modo ofrecerían un notable ruido para la clasificación temática (Schiewe *et al.*, 2001). Se han propuesto diversos criterios para realizar esa segmentación previa de la imagen, siendo los más habituales los que parten de reducir la resolución radiométrica de la imagen, aplicando posteriormente algún criterio de agregación espacial basado en la adyacencia (Lobo, 1997).

La figura 7.49 incluye un ejemplo de segmentación de la imagen Torrel00. Es fruto de aplicar el algoritmo de segmentación propuesto por Gong y Howarth (1992), el cual, a partir de una imagen multibanda genera una imagen de un solo canal, con un número reducido de categorías, utilizando criterios de compactación similares a los que vimos para la clasificación no supervisada. Este algoritmo se utiliza para alimentar un clasificador de contexto, desarrollado por los mismos autores, que parte de los grupos espectro-espaciales generados en esta fase.

El segundo grupo de clasificadores de contexto refiere a aquellos que incorporan este criterio en el propio algoritmo de asignación. Se trata, en términos sencillos, de realizar la asignación de un determinado píxel de la imagen no sólo a partir de sus ND, sino también de los correspondientes a los píxeles vecinos. Una manera concreta de aplicar este criterio sería incorporar alguna variante de la vecindad espacial a alguno de los criterios de clasificación que vimos anteriormente. Por ejemplo, en el caso del algoritmo de máxima probabilidad puede considerarse la probabilidad de asignación de los píxeles vecinos (Richards, 1993):

$$p'(x / c_i) = \frac{p(x / c_i)\, q(x / c_i)}{\sum_{i=1,m} p(x / c_i)\, q(x / c_i)} \qquad [7.42]$$

donde indica la probabilidad de que el píxel x pertenezca a la categoría c_i, para todas las categorías m y $q(x / c_i)$ una función de vecindad, definida por el usuario, que habi-

tualmente está relacionada con la distancia. Éste o similares criterios se han empleado con buenos resultados en distintas clasificaciones temáticas (Danjoy y Sadowski, 1978; González y López, 1991).

Finalmente, podemos señalar aquellos criterios que introducen el contexto para refinar los resultados de la clasificación. Resulta bastante frecuente que los resultados de una clasificación digital adolezcan de una excesiva fragmentación. Manchas de una cierta categoría se encuentran salpicadas por píxeles asignados a otras categorías, perdiéndose su unidad geográfica y dificultando la interpretación y posterior representación cartográfica de los resultados. Este fenómeno se denomina coloquialmente en la bibliografía anglosajona efecto de «sal y pimienta» *(salt and pepper)* y se debe, por un lado, a que la mayor parte de los criterios de asignación no tienen en cuenta la pertenencia de píxeles vecinos y, por otro, a la propia complejidad del paisaje, directamente relacionada con la aparición de píxeles mixtos —fronterizos a dos o más categorías—, que son los principales responsables de la discontinuidad visible en el mapa.

Para solventar este problema suele aplicarse una técnica de suavización de resultados, similar en la concepción, aunque no en la ejecución, a los filtros de paso bajo. Como ya hemos visto, sobre la imagen clasificada no puede aplicarse un filtro aritmético, ya que sus ND no guardan una relación cuantitativa entre sí, sino que sólo son etiquetas que definen las distintas categorías. Cualquier promedio de píxeles vecinos introduciría cambios imprevisibles en la clasificación, ya que no se trata de una imagen de tono continuo, sino de una imagen categorizada, en donde no tiene sentido establecer análisis de gradientes. Por esta razón se aplican sobre la imagen otros esquemas de filtraje, basados sobre medidas categóricas en lugar de sobre promedios (Thomas, 1980). El objetivo último es reasignar aquellos píxeles aislados o poco significativos, facilitando una distribución espacial más nítida de las distintas categorías. Para ello se procede a comparar la clase asignada a cada píxel con la que ofrecen los vecinos. Si esa clase es la misma de la mayor parte de los píxeles del entorno se mantiene la asignación original; caso contrario, se modifica. Normalmente esta comparación se realiza a partir de una ventana móvil de 3 × 3 píxeles, si bien la técnica es independiente de su tamaño. En la terminología habitual se distinguen, a este respecto, dos tipos de filtros (fig. 7.50):

1. Filtro modal. El píxel situado en el centro de la matriz se asigna a la categoría más frecuente entre los píxeles vecinos, siempre que, lógicamente, no pertenezca ya a ella.
2. Filtro de mayoría. El píxel central se asigna a la categoría que cuente con la mitad más uno de los píxeles vecinos. En caso de que ninguna categoría rebase ese valor, el píxel central mantiene su asignación primitiva.

La elección entre uno u otro método depende del tipo de paisaje analizado y del algoritmo que se haya empleado en la clasificación. Lógicamente, el primero ofrece una mayor generalización que el segundo, por lo que puede ser conveniente su empleo en caso de paisajes muy complejos y cuando la escala de trabajo sea regional o global. Se ha comprobado por diversos autores que la aplicación de esta técnica proporciona un aumento significativo de la exactitud conseguida en la clasificación (Booth y Oldfield, 1989; Castro y Chuvieco, 1995). Este efecto es debido, principalmente, a la eliminación de asignaciones anómalas debidas a píxeles de borde. Uno de los proble-

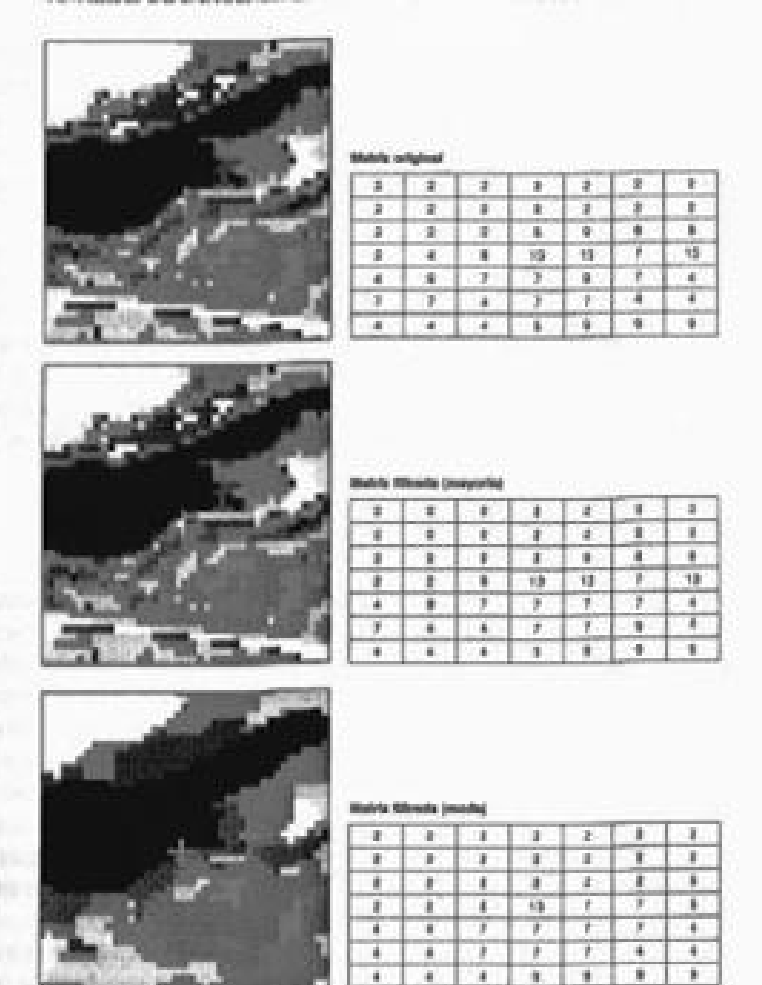


FIG. 7.50. *Reducción del ruido de la escena mediante filtros categóricos.*

mas que presenta este método, sin embargo, es la difícil decisión sobre el tamaño de la ventana y el criterio de filtrado, ya que pueden provocar el efecto deseado en unas zonas de la imagen, pero ser excesivo o insuficiente en otras. Para solventar este problema se ha propuesto realizar la reasignación a partir de unos umbrales de tamaño variable, que filtren o no cada categoría a partir de un umbral de superficie crítico fijado para cada clase. Por debajo de ese valor se considera que la fragmentación de la imagen implica ruido en la clasificación y el polígono es asignado a otra categoría (Barr y Barnsley, 2000). En el ejemplo propuesto por Barr y Barnsley, este esquema funcionó mucho mejor que los filtrados de mayoría convencionales para un ejemplo de cartografía urbana realizado a partir de imágenes aéreas de alta resolución.

Otros criterios de re-clasificación pueden basarse en las propiedades espaciales de los píxeles, como su distancia, conectividad o inclusión. Un sencillo ejemplo del interés de estas relaciones es la discriminación entre cultivos herbáceos de regadío y par-

ques urbanos. Ambas cubiertas presentan un comportamiento espectral similar, ya que de hecho ambas se riegan en verano y están compuestas por vegetación herbácea. Por tanto, para separarlas es preciso acudir al contexto espacial: un parque estará emplazado en el interior de un área urbana, por lo que puede considerarse como tal si los píxeles situados a un cierto radio han sido asignados a la categoría urbana, asignándose a cultivos de regadío en caso contrario.

Pueden proponerse otros análisis basados en el contexto para realzar la clasificación temática. Por ejemplo, aplicando ciertos indicadores de idoneidad en función de la categoría contigua a cada píxel. Habitualmente, estos análisis se basan en matrices de aptitud, que ponderan el interés de que una categoría se presente junto a otra para un determinado objetivo. Un campo interesante de aplicación es la cartografía de hábitats idóneos para ciertos animales (Congalton *et al.*, 1993*b*). La mezcla entre ciertas cubiertas vegetales complementa su dieta, haciendo esos lugares más atractivos para establecerse.

2.3.6. *Redes neuronales*

Entre las nuevas técnicas de clasificación de imágenes, una de las que cuenta con más potencialidad es el empleo de redes neuronales artificiales (RNA). En esencia, las RNA se utilizan para predecir un cierto comportamiento complejo, habitualmente a partir de una muestra de entradas y salidas observadas. Con los datos de esa muestra, la red «aprende» a reconocer el resultado a partir de los valores de entrada, clasificando el resto de las observaciones de acuerdo a esas reglas. Intentan, no siempre con mucho éxito, simular el comportamiento del cerebro humano (de ahí su nombre), mediante la interconexión múltiple entre unidades de activación (llamadas neuronas).

Aunque la descripción completa de esta técnica rebasa el enfoque de este libro, nos parece conveniente dedicar unos párrafos a explicar los conceptos generales de las RNA, así como su empleo en el contexto de la clasificación de imágenes.

Una RNA está formada por un conjunto de elementos simples (neuronas, unidades de proceso), distribuidas en capas (fig. 7.51). Las unidades que forman una capa están conectadas con la capa o capas inmediatas a través de unas funciones de activación (sigmoidales, habitualmente). Esas funciones se definen a partir de una serie de pesos ($w_{i,j}$), que se calculan de modo iterativo en el proceso de aprendizaje de la red. El objetivo de este aprendizaje es estimar unos resultados conocidos a partir de unos datos de entrada (muestra de control), para posteriormente calcular resultados desconocidos a partir del resto de datos de entrada. El aprendizaje se realiza a partir de todas las unidades que forman la red, variando el conjunto de los pesos en iteraciones sucesivas. Cada unidad de la red proporciona un valor de salida a partir de los valores de entrada, del modo siguiente (Richards, 1993):

$$o = f(wx + \theta) \qquad [7.42]$$

donde o indica el resultado, θ es un umbral (en muchas ocasiones se deja a cero), w un vector con los pesos que unen las distintas unidades de la red, y x el vector de entradas. Ese valor de salida puede ser a su vez la entrada de unidades situadas en la capa siguiente o en la anterior, dependiendo del tipo de red.

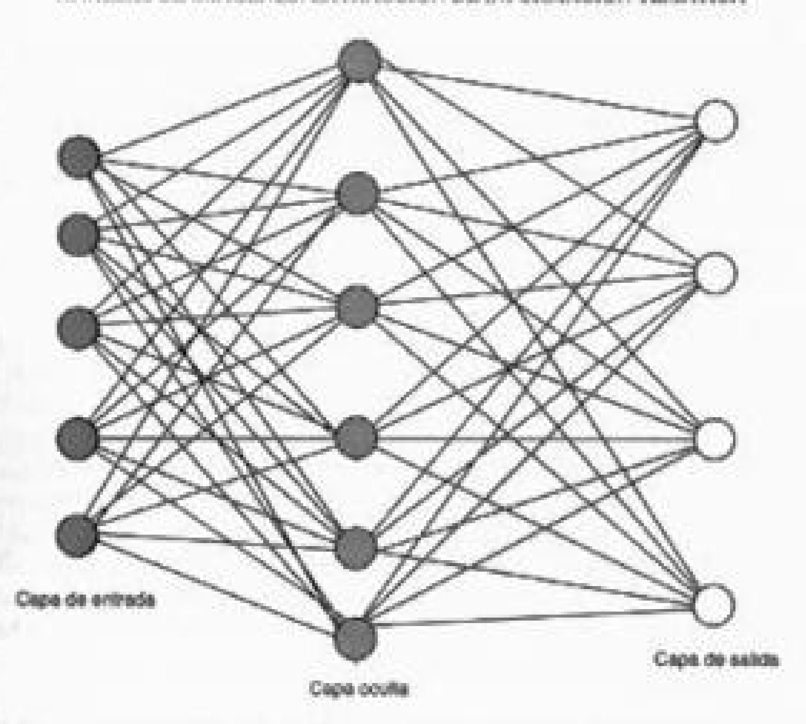


FIG. 7.51. *Esquema de una red neuronal.*

El número de unidades y de capas depende de las condiciones del problema en estudio, siendo más complicado el proceso de aprendizaje cuanto mayor dimensión tiene la red. En clasificación de imágenes es frecuente que las RNA estén formadas por tres capas, denominadas de entrada, oculta y de salida. El objetivo de la capa oculta es lograr funciones que permitan generar funciones de discriminación más flexibles. El número de las unidades de entrada está en relación con los valores que sirvan para entrenar a la red, habitualmente una por cada banda empleada en la clasificación, si bien es necesario utilizar una cadena de unidades por banda para poder codificar el rango completo de ND (0 a 255) (Benediktsson *et al.*, 1990). El número de unidades de salida coincide con el de clases que pretendan clasificarse, mientras el número en la capa oculta puede variar, aunque se recomienda sea al menos igual al de la capa de entrada (Richards, 1993).

El punto más álgido de las RNA es el denominado «aprendizaje» de la red, esto es la adecuada configuración de las conexiones y pesos entre las unidades de la red para lograr un resultado óptimo. Entre los diversos criterios de aprendizaje, el más conocido es el denominado de retro-propagación. Tiene por objetivo encontrar un conjunto de pesos que asegure que cada vector de entrada producido por la red sea el mismo, o muy similar, al de salida conocido. Su formulación puede sintetizarse de la siguiente forma (para un análisis más detallado, véase Rumelhart *et al.*, 1986 y Richards, 1993, pp. 207-224):

1. Asignar unos pesos arbitrarios a la red para obtener unos resultados a partir de los valores de entrada (en nuestro caso, los ND de las áreas de entrenamiento en las

distintas bandas). Esos resultados se contrastan con la categoría a la que pertenece cada píxel de entrenamiento (introducida por el usuario). Esto permite obtener una tasa de error inicial. La medida habitual del error es la desviación cuadrática entre el resultado esperado (t_k) y el producido por la red (o_k):

$$E = \sqrt{\sum_{k=1,n} \sum_{m=1,c} (t_{k,m} - o_{k,m})^2} \qquad [7.43]$$

para todo resultado esperado m (en nuestro caso para las c categorías) en todas las unidades de entrada k (en nuestro caso las bandas, n, a introducir en la clasificación).

2. A partir de ahí se van modificando iterativamente los pesos en las distintas capas, desde la de salida hasta la de entrada, con el objetivo de reducir el error global (se propaga el error hacia atrás, de ahí el nombre del ajuste), hasta que éste sea muy pequeño o nulo (en ese caso, todas las muestras introducidas en el aprendizaje estarían bien clasificadas), o bien se hayan cumplido el número de iteraciones indicadas por el intérprete. El número de iteraciones para lograr el objetivo marcado por el usuario (el nivel de convergencia de la red) puede ser muy elevado, dependiendo de la complejidad del problema (en clasificación de la cubierta del suelo se han propuesto hasta 250.000 iteraciones: Civco, 1993).

Para ilustrar el proceso de aprendizaje puede ser de interés estudiar un sencillo ejemplo de clasificación propuesto por Richards (1993, pp. 219-223). En ese caso se trata de un conjunto de seis elementos que forman dos categorías (c_1 y c_2) que tratan de discriminarse por funciones lineales (fig. 7.52). Los valores de estos seis elementos son:

$$c_1 = (-4,3)(-4,-3)(-1,0)$$

$$c_2 = (-2,-3)(-2,3)(1,0)$$

Claramente se observa en la fig. 7.52*b* que estas dos clases no son separables por ecuaciones lineales sin cometer algún error en la asignación. Para clasificarlas se establece una RNA con tres capas: dos unidades de entrada, dos ocultas y una de salida, lo que implica seis conexiones y, por tanto, calcular seis pesos y el valor del error (θ). Siguiendo los criterios antes indicados se inicia el entrenamiento de la red con unos pesos arbitrarios, que dan lugar a un margen relativamente grande de error (0,461: tabla 7.10). Como puede observarse, los pesos se modifican en cada iteración (aquí se ha resumido la tabla de resultados), así como el error residual, que va disminuyendo hasta un valor que consideramos adecuado. En ese momento, los pesos sirven para calcular las conexiones entre las unidades de la red:

De la capa de entrada a la capa oculta:

$$o_1 = 2{,}901\,x_1 - 2{,}976\,x_2$$

$$o_2 = 2{,}902\,x_1 - 2{,}977\,x_2$$

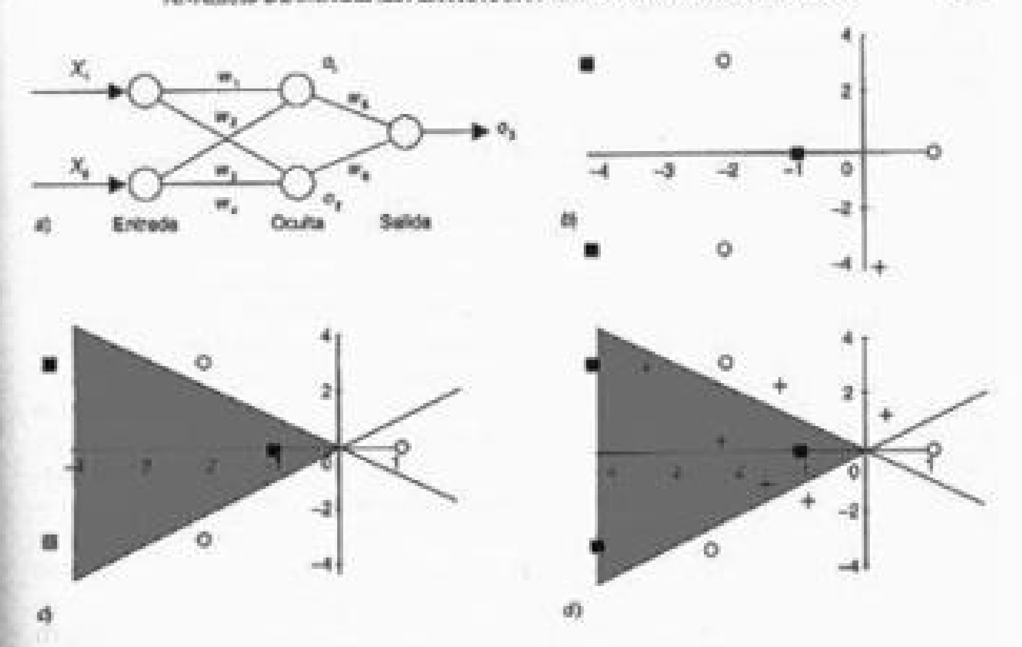


FIG. 7.52. *Ejemplo de aplicación de una red neuronal.* (Richards, 1993.)

y de la capa oculta a la de resultados:

$$o_3 = 4{,}785\,o_1 + 4{,}784\,o_2$$

La asignación de una unidad de la muestra a una de las dos clases se hace en función de los resultados que ofrezca o_3. Como se trata sólo de dos categorías, la entrada se asigna a la clase 1 si el resultado o_3 está más cerca de 0, y a la 2 si está más cerca de 1.

Si igualamos a cero las dos primeras ecuaciones resultan entre ambas un marco idóneo para separar las dos categorías de nuestro ejemplo (fig. 7.52*c*). Ahora bien, esas rectas pueden considerarse como un paso intermedio (están en la capa oculta) para obtener la ecuación final, en la cual se discriminan las dos categorías perfectamente con una función lineal. Simplificando las cosas, esas ecuaciones intermedias pueden concebirse como un medio de transformar el espacio de medida original para

TABLA 7.10. *Valores de los coeficientes de ponderación y del error en la red del ejemplo para distinto número de iteraciones (Richards, 1993)*

Iteración	W_1	W_2	W_3	W_4	W_5	W_6	*Error*
0	0,050	0,100	0,300	0,150	1,000	0,500	0,461
1	0,375	0,051	0,418	0,121	0,951	0,520	0,424
5	0,606	0,007	0,570	0,117	1,240	0,909	0,391
10	0,642	−0,072	0,641	0,196	1,464	1,034	0,378
50	2,224	−2,215	2,213	2,216	3,302	3,259	0,040
150	2,810	−2,834	2,810	2,835	4,529	4,527	0,007
250	2,901	−2,976	2,902	2,977	4,785	4,784	0,005

lograr una separación idónea entre los miembros de cada clase. Habitualmente no se utilizan ecuaciones lineales para obtener los valores de salida de una neurona, sino funciones más complejas, como sigmoides (el valor de salida está comprendido entre 0 y 1), o hiperbólica-tangente (valor de salida de –1 a +1) (Civco, 1993).

Una vez realizado el aprendizaje, pueden introducirse nuevos casos de asignación desconocida, para que la RNA los clasifique en función de las ponderaciones previamente calibradas. En este ejemplo se añaden algunos casos en las proximidades de los inicialmente planteados; en todos ellos la asignación es correcta (fig. 7.52*d*). El proceso de clasificación se realiza simplemente asignando valores a las variables de entrada x_1 y x_2. Como ya hemos indicado, el valor de salida o_1 se redondea al entero más cercano para asignar el caso a la primera o segunda categoría.

En el contexto de la clasificación de imágenes se ha comprobado la potencialidad de las RNA como alternativa a los clasificadores estadísticos tradicionales, especialmente cuando no pueden asumirse distribuciones normales de las categorías (Bendiktsson *et al.*, 1990), ya que las RNA son independientes del tipo de distribución. En varias ocasiones se ha contrastado su utilidad frente a estos clasificadores, lográndose resultados comparables o aún mejores. En general, la discriminación de las muestras de entrenamiento resulta más adecuada que con los clasificadores convencionales (Benediktsson *et al.*, 1990; Foody, 1995), pero la asignación propiamente de la imagen muestra una gran dependencia de la calidad del entrenamiento. Las RNA pueden incluir bandas auxiliares no espectrales, que pueden ser incluso nominales, como mapas de suelos o de propiedad de la tierra. En algunos trabajos se ha comprobado la gran robustez de esta técnica (poco sensible a valores extremos) y su habilidad para incluir elementos texturales, ofreciendo así una clasificación con menos ruido que la basada en los métodos píxel a píxel convencionales (Bischof *et al.*, 1992; Civco, 1993; Hepner *et al.*, 1990). También se ha sugerido su aplicación a la estimación de parámetros físicos, como el índice de área foliar y el contenido de clorofila (Fourty y Baret, 1997), así como técnica alternativa de ajuste para modelos de evaluación de riesgo (Carvacho, 1998; Vega-García *et al.*, 1996).

Entre los problemas de las RNA cabe citar la falta de criterios generales para diseñar la estructura de la red (número de capas, unidades en cada capa), reduciéndose su empleo a una cuestión de prueba y error; su lento y tedioso entrenamiento (que desaconseja su empleo cuando el número de clases o de bandas es muy grande: Clark y Cañas, 1995); la posibilidad de que se encuentre mínimos locales y de que se produzca un sobre-entrenamiento de la red. Esto ocurre cuando se ajustan muy bien los datos de entrada, pero la red es poco generalizable a otros datos (Mather, 1998). Para evitar esto suele dividirse la muestra de aprendizaje en dos grupos, uno para calcular los pesos y otro para verificar el ajuste. También pueden plantearse las redes para la clasificación no supervisada, ya que existe algunos criterios de aprendizaje que no requieren una previa definición de las clases deseadas.

En la fig. 17* se incluye un ejemplo de clasificación con redes para la imagen Torrel00. Se emplearon tres programas para obtener la clasificación. En el primero se crean las condiciones generales del análisis: número de unidades de entrada (6 en nuestro caso, una por banda), número de capas ocultas (1 en nuestro caso), número de clases de entrenamiento y valor temático de cada clase. En nuestro caso se trata de las 7 categorías de cobertura previamente descritas. El siguiente programa se dedica a entrenar a la red a reconocer las categorías que quieren discriminarse. Existen algunos parámetros de control que modifican el proceso de aprendizaje, como el índice de momento, el índice de aprendizaje, el error máximo normalizado, el individual y el número máximo de iteraciones. Para nuestro caso se aceptaron los valores recomendados por el programa: 0,9 para el momento; 0,1 para el aprendizaje; 0,01 para el máximo error; 0,001 para el máximo error individual, y 1.000 iteraciones. Después de completar el número de iteraciones, el error máximo se situó en 0,0354. Aunque no garantizaba el indicado previamente, nos pareció suficiente para este ejemplo didáctico. Tras entrenar a la red, el paso siguiente es asignar los píxeles de la imagen a cada categoría temática, conociendo los pesos obtenidos previamente. La clasificación por RNA fue más rápida que la realizada con el algoritmo de máxima probabilidad, descontando lógicamente el lento proceso de aprendizaje. Comparándola con las clasificaciones antes comentadas se observa una mejor discriminación del pinar, que aparece mejor representado en las zonas serranas del NW de la imagen, mientras el suelo descubierto, principalmente roquedo en esos sectores, se asigna en algunos sectores al matorral, por lo que éste incrementa su extensión. En el resto de la imagen, el suelo descubierto se clasifica bien, así como los pastizales y cultivos de secano, excesivamente representados en la clasificación de máxima probabilidad. La combinación matorral-encinar sigue sobre-dimensionada, especialmente en el centro y norte de la imagen (fig. 17*).

2.3.7. *Clasificación borrosa*

Previamente hemos señalado el interés de las técnicas que permiten obtener información sobre la mezcla en el interior de un píxel. Considerar un píxel como un compuesto de varios elementos resulta cada vez más común, si se considera el espacio como un continuo, sin barreras muy precisas, al menos en lo que se refiere a la mayor parte de las variables ambientales (Mather, 1999).

En el campo de la clasificación, este enfoque lleva consigo modificar los planteamientos convencionales, en donde cada píxel se asigna a una sola categoría. De ahí que últimamente se denomine a estos clasificadores como «rígidos» *(hard classifiers)*. Estos clasificadores pueden conducirnos a errores notables, cuando existan píxeles mixtos. Por ejemplo, en el criterio de máxima probabilidad, un píxel se asigna a la clase más probable independientemente de que la probabilidad de pertenencia a esa categoría sea muy superior a pertenecer al resto (digamos que 0,9 sobre 0,1) o que sólo la supere por un estrecho margen (0,55 frente a 0,45). En el primer caso, el error de clasificar ese píxel es bastante bajo, mientras en el segundo la asignación es muy arriesgada.

Las nuevas técnicas de clasificación borrosa *(fuzzy)* permiten aliviar este problema. En pocas palabras, se considera una pertenencia borrosa a una categoría cuando se admite un grado de pertenencia. En este enfoque, cada píxel se etiqueta en varias categorías, con un valor más o menos alto en función de su similitud espectral (fig. 7.53). Convencionalmente, la función de pertenencia corresponde a una distribución binaria (0 no pertenece, 1 pertenece), pero puede concebirse un función de pertenencia comprendida entre 0 y 1, lo que permitiría una asignación simultánea a varias categorías, con diferentes grados de pertenencia (Wang, 1990):

$$U_{i,j} = f(\mathrm{ND}_i) \qquad [7.44]$$

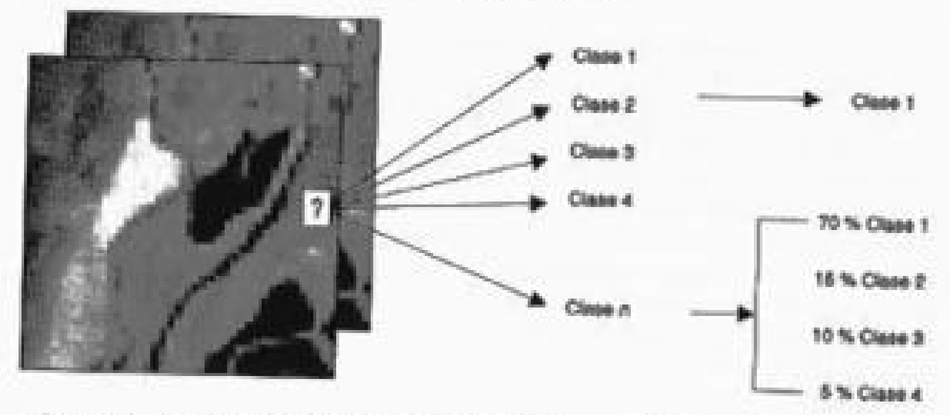


FIG. 7.53. *La clasificación borrosa permite asignaciones múltiples en el mismo píxel.*

donde $U_{x,i}$ indicaría el grado de pertenencia del píxel x a la clase i, y puede ser un número real comprendido entre 0 y 1.

En aplicaciones de teledetección, los métodos más habituales para obtener esos valores de pertenencia son la variante borrosa de máxima probabilidad (Maselli *et al.*, 1995; Wang, 1990) y una variedad de análisis no supervisado, denominado c-medias borrosas (Fisher y Pathirana, 1990; Foody, 1992). Por simplificar la exposición nos vamos a centrar en el primer criterio, ya que es muy similar al de máxima probabilidad antes analizado. En el trabajo de Fisher y Pathirana (1990) se incluye la formulación completa del criterio c-medias borrosas.

En un enfoque de lógica borrosa, para calcular el grado de pertenencia de un píxel a las distintas categorías de la leyenda, asumiendo una distribución de probabilidad normal en las categorías, podemos emplear las siguientes definiciones del vector de medias y la matriz de varianza-covarianza (Wang, 1990):

$$M_A^* = \frac{\sum_{i=1,n} U_A(M_i)\, M_i}{\sum_{i=1,n} U_A(M_i)} \qquad [7.45]$$

y

$$V_A^* = \frac{\sum_{i=1,n} U_A(M_i)(M_i - M_A^*)(M_i - M_A^*)^t}{\sum_{i=1,n} U_A(M_i)} \qquad [7.46]$$

donde U_A indica el grado de pertenencia a la clase A, M el vector de ND formado por los n píxeles utilizados en la muestra, y V_A la matriz de varianza-covarianza para esa clase. El asterisco en el vector M_A y la matriz V_A indica que se trata de medias y varianza-covarianza para un espacio borroso (*fuzzy*).

A partir de esos dos valores puede calcularse la probabilidad de pertenencia a ese espacio, variando ligeramente las fórmulas de la probabilidad bayesiana:

$$p^*(x/A) = (2\pi)^{-m/2}\, |V_A^*|^{-0,5} \exp\{-0,5\,(M_x - M_A^*)^T\, V_A^{*-1}\,(M_x - M_A^*)\} \qquad [7.47]$$

El resultado de este cálculo permite conocer la probabilidad de incluirse en cada categoría *A*. Esa probabilidad se considera el grado de pertenencia de ese píxel a dicha categoría. Por tanto, se obtienen tantas imágenes clasificadas como categorías se consideren. El ND de cada una de esas imágenes indica el grado de pertenencia a las distintas categorías.

Las áreas para estimar las estadísticas de entrenamiento pueden ser homogéneas —como en la clasificación convencional— o, ahí la novedad, heterogéneas, con componentes mixtos, siempre que se conozca su grado de mezcla. Las aplicaciones de esta lógica borrosa son de especial interés cuando se pretenda analizar coberturas con alto grado de mezcla, como es el caso de las categorías urbanas o cuando se aborden inventarios de vegetación. En varios trabajos se ha obtenido una buena correlación entre el grado de cobertura de distintas clases, observado en fotografía aérea de alta resolución, y los grados de pertenencia ofrecidos por la clasificación borrosa, tanto para clases urbanas (Fisher y Pathirana, 1990), como para densidades de vegetación (Foody, 1992). Un interesante campo de aplicación es el inventario forestal, donde este tipo de clasificación puede facilitar datos de gran interés para la estimación global de densidades y superficies. En un trabajo piloto realizado en Italia, los ajustes entre las observaciones de terreno y los componentes *fuzzy* son mucho más altos que para las bandas originales (reducidas mediante componentes principales), especialmente en la estimación del área basal (Maselli *et al.*, 1995).

Aunque en el origen esta técnica procede de una concepción bastante distinta al análisis lineal de mezclas espectrales (ALME) previamente analizado, los resultados que ofrecen tienen bastante en común. Ambas técnicas pretenden derivar información sub-píxel, expresando el grado de pertenencia (*fuzzy*) o la proporción (ALME) de una determinada categoría. Son pocos los trabajos que han comparado las ventajas e inconvenientes de ambas técnicas, en cuanto a eficacia para resolver las mezclas, tiempo de cálculo y limitaciones. Cuando se han abordado simultáneamente, los resultados parecen ofrecer una gran coincidencia entre los dos métodos (Foody y Cox, 1994). Este concepto de asignación borrosa puede extenderse a la integración de variables de distintas fuentes o a la comparación multitemporal, permitiendo la posibilidad de señalar distintas intensidades de cambio (Foody, 2001).

En la figura 7.54 aparece un ejemplo de clasificación utilizando un algoritmo no supervisado de k-medias borrosas incluido en el programa XPACE. Se introdujo un valor intermedio, entre los recomendados por el programa, para los parámetros de control del agrupamiento (normalización de las medias borrosas y distancia entre las mismas). Se señaló un máximo de 3 grupos, 20 iteraciones y un 0,01 para el porcentaje de píxeles que podían cambiar de grupo entre iteración. Puesto que se trata de un proceso bastante lento, se seleccionaron para el análisis únicamente las bandas ETM+ 2, 3, 4 y 5. La figura recoge los grados de pertenencia de los píxeles de la imagen a dos de las categorías identificadas por el programa, que corresponden a vegetación con distintos grados de densidad y actividad clorofílica.

La figura 7.55 muestra otro ejemplo, tal vez más obvio, de este enfoque borroso en la clasificación. Recoge una asignación múltiple realizada a partir de una clasificación de máxima verosimilitud de la imagen Barrax99. En este caso se grabaron los

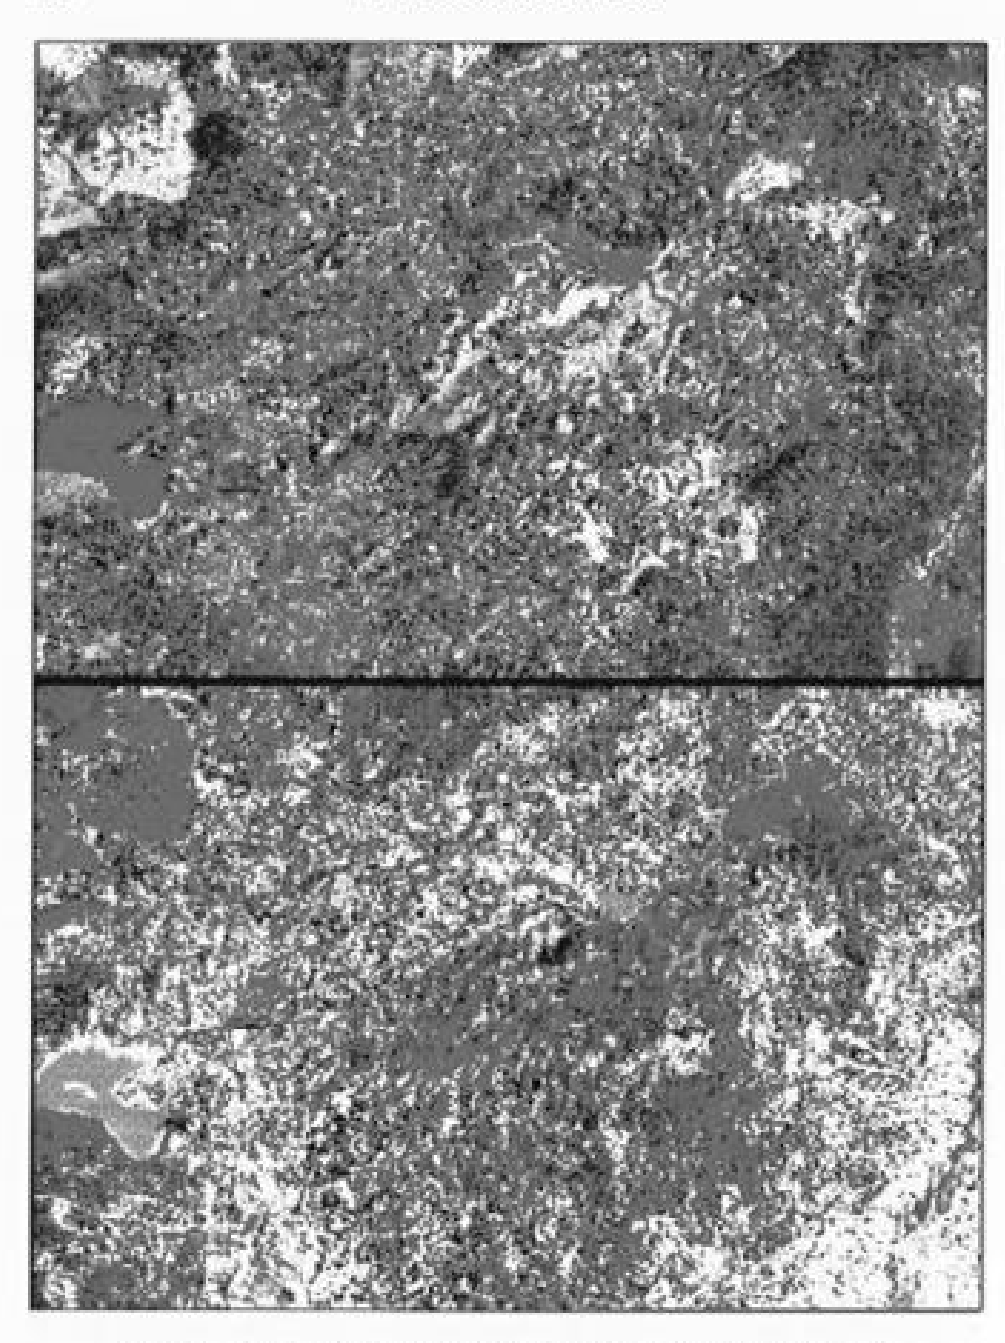


FIG. 7.54. *Resultados de una clasificación borrosa sobre la imagen Torre100 para dos categorías: arriba, vegetación perennifolia; abajo, suelos con escasa vegetación.*

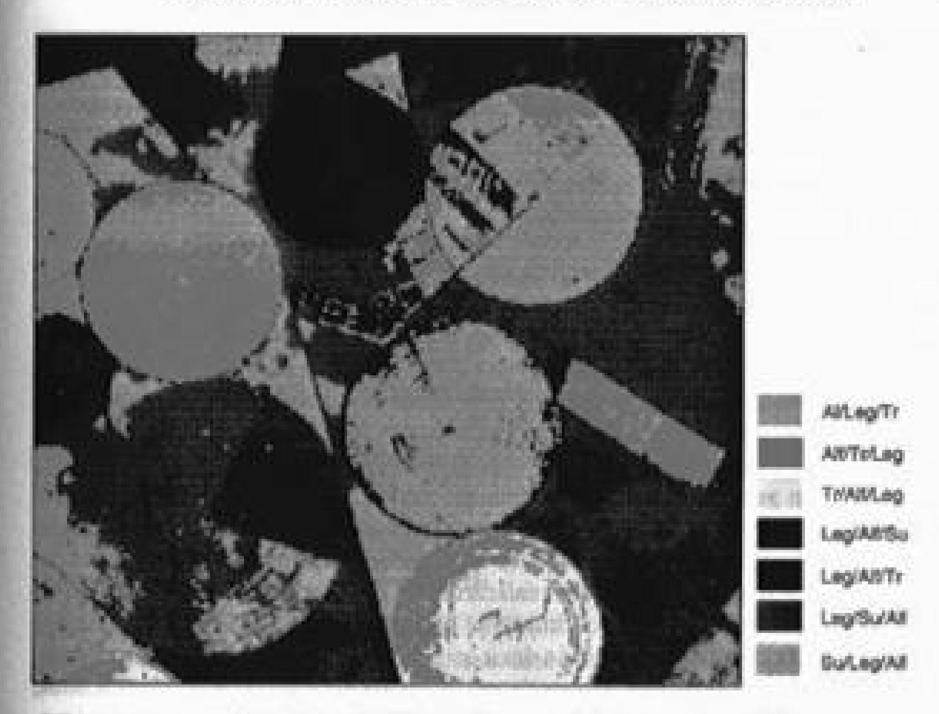


FIG. 7.55. *Clasificación borrosa de la imagen Barrax99* (Alf: Alfalfa; Leg: Legumbres; Tr: Trigo; Su: Suelo).

cálculos de probabilidad para cada píxel, de tal manera que pueden reconstruirse sus asignaciones potenciales al resto de categorías de interés. Por ejemplo se distinguen los píxeles que se asignaron a la categoría alfalfa en función de a qué categoría lo hicieron en segunda y tercera opción (legumbres, trigo y suelo son las alternativas). De esta forma podemos distinguir entre los píxeles que aun clasificándose como alfalfa tienen una mayor tendencia a ser trigo, legumbres o suelo, en distinto orden, y por tanto qué tipo de estado vital tenían en el momento de adquirirse los datos. Por ejemplo, si un píxel es categorizado como alfalfa y suelo se tratará de una zona con menor cobertura vegetal que otra clasificada como alfalfa y trigo.

2.4. Obtención y presentación de resultados

Independientemente del método empleado en la clasificación digital, los resultados se almacenan en una nueva imagen, similar a las originales, en cuanto a estructura y tamaño, pero con la importante diferencia de que el ND de cada píxel no corresponde a un valor de reflectividad, sino a la categoría a la que se asignó. En definitiva, obtenemos una nueva matriz numérica, similar a la original, aunque de dos dimensiones, pues se ha condensado la información espectral (varias bandas) en una sola clase temática. Esa nueva imagen puede ser el producto final del trabajo, o servir como estadio intermedio de un proyecto más amplio, en donde la teledetección se combine con otro tipo de variables espaciales.

Esa nueva imagen puede dar lugar a dos tipos de productos: cartográficos y estadísticos. En el primer caso se trata de convertir la imagen clasificada en un mapa; en el segundo, de realizar un inventario a partir de los ND que componen esa imagen.

2.4.1. *Productos cartográficos*

La imagen clasificada puede convertirse en un mapa temático, similar a los convencionales, empleando algunas técnicas ya comentadas en anteriores capítulos. En primer lugar conviene simplificar los resultados de la clasificación aplicando algún filtro modal, de tal forma que se generalicen los polígonos que forman la clasificación. Esto facilita también su conexión con un SIG como luego veremos.

Seguidamente se requiere dotar a esa imagen de una validez cartográfica, de tal forma que se ajuste a un sistema de coordenadas determinado. Por cuanto el resultado de la clasificación es también una imagen digital, pueden aplicarse sobre ella los métodos de corrección geométrica antes comentados (cap. 6, apdo. 6.3). Basta identificar puntos comunes entre la imagen y el mapa de referencia, aplicar algún polinomio de transformación, y proceder al trasvase de los ND a su nueva posición. Conviene recordar que, en este caso, ese trasvase debe realizarse con el criterio del vecino más próximo, puesto que cualquier otro —que implique promediar las categorías— invalidará los resultados de la clasificación. Obvia decir que los puntos de control pueden localizarse sobre las bandas originales, ya que tienen la misma geometría de las clasificadas, y aplicar luego sobre éstas el modelo de corrección. Localizar puntos sobre una imagen clasificada sería muy problemático, ya que se pierden la mayor parte de los rasgos lineales de la imagen original.

Una vez posicionada correctamente, la imagen clasificada requiere contar con una serie de elementos gráficos, que faciliten su lectura. Uno importante es generar una tabla de color apropiada al significado temático de cada una de las categorías. En este sentido, conviene respetar las convenciones establecidas en la asignación temática de colores: por ejemplo, rojo para las zonas urbanas, verde para las forestales, ocre para las agrícolas, etc. (Anderson *et al.*, 1976; Coleman, 1968), en lugar de atribuir colores arbitrarios a las categorías.

Como ya se comentó, la manipulación numérica del color ofrece al intérprete una amplia paleta de colores: de 0 a 255 niveles, por cada uno de los tres cañones de color. De esta forma, para diseñar un color apropiado a cada categoría basta indicar tres valores numéricos, entre 0 y 255, que expresen el nivel de R, V, A, asignado a dicha clase. En clasificaciones temáticas, quince o veinte colores, bien discriminables entre sí, serán suficientes para visualizar el resultado. Un mayor número de categorías complicaría notablemente la interpretación y, en consecuencia, la legibilidad del documento final.

Basta añadir al mapa un conjunto gráfico apropiado para que se culmine el proceso de edición. Elementos de interés, en este sentido son: una leyenda de color, que identifique las categorías presentes en el mapa y el color que se les asigna; una escala gráfica, para identificar adecuadamente la proporción del área representada, y una serie de rótulos identificativos de la zona y/o del proceso realizado. Caso de que se disponga de información vectorial complementaria, como carreteras o ríos, puede ser conveniente superponerlos a la imagen como líneas de referencia. La figura 7.56 reco-

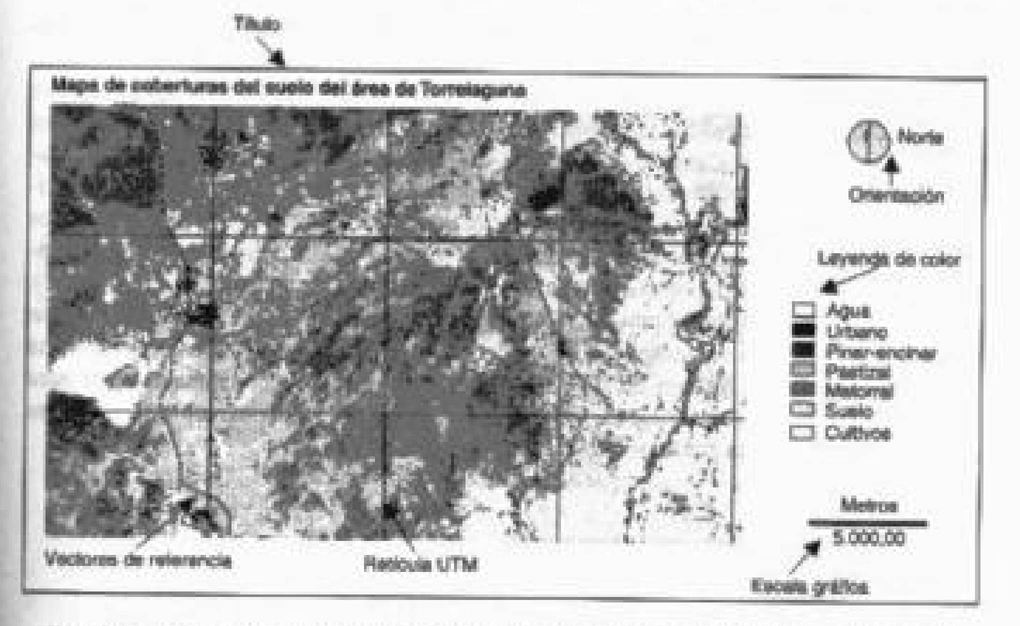


FIG. 7.56. *Elementos cartográficos incorporados a la clasificación de la imagen Torrel00.*

ge un ejemplo de algunos elementos cartográficos que pueden asociarse a una imagen clasificada.

Una vez que el resultado es satisfactorio, el último paso se dirige hacia la reproducción de la imagen clasificada en un soporte permanente, ya sea papel o película, utilizando cualquiera de los periféricos disponibles. Para productos cartográficos de amplia cobertura, la impresión puede realizarse en línea, si uno dispone de un periférico de gran formato, o bien salvar la composición cartográfica como archivo e imprimirlo posteriormente en un centro que disponga de ese equipo. Actualmente hay formatos gráficos bastante estándar (.TIF, .EPS) que permiten acceder fácilmente a periféricos de gran calidad que no tienen por qué estar relacionados con aplicaciones específicas de teledetección. Muchas empresas de artes gráficas, por ejemplo, disponen de estos equipos (*plotters* de inyección de tinta de diverso tamaño y resolución). En consecuencia, puede ser más conveniente acudir a ellos cuando, esporádicamente, sea precisa una salida gráfica de mayor tamaño, en lugar de realizar la fuerte inversión que implican. Lógicamente, eso dependerá de la intensidad de uso que se vaya a realizar de estos aparatos.

2.4.2. *Productos estadísticos*

El inventario superficial de los resultados es una de las principales ventajas de la clasificación digital. Una simple tabulación de frecuencias permite obtener el inventario del área clasificada; esto es, el número de píxeles incluidos en cada una de las categorías. Puesto que es conocida la dimensión superficial de cada píxel, resulta inmediato obtener la extensión ocupada por cada categoría. Por el contrario, para alcanzar el mismo objetivo el análisis visual requiere planimetrar cada una de las zo-

nas delimitadas por el intérprete, lo que resulta una labor lenta, fatigosa y, frecuentemente, inexacta.

El tratamiento digital permite calcular superficies sobre toda la imagen, o sobre polígonos determinados. Si esos polígonos coinciden con unidades administrativas (municipios, comarcas), puede obtenerse un inventario de gran interés para las estadísticas oficiales. Por ejemplo, una clasificación agronómica de la imagen puede facilitar estadísticas de cultivo a veces inaccesibles por medios convencionales. Varios trabajos han ensayado el uso alternativo de esta metodología frente a las fuentes de información tradicionales, como el catastro o las hojas de cultivos (GDTA-CEE, 1982).

A modo de ejemplo, la tabla 7.11 recoge el inventario de los tipos de ocupación de la imagen de nuestro ejemplo, tal y como aparecen clasificados mediante máxima probabilidad y RNA. Vemos las notables diferencias entre ellas, especialmente para las categorías más dominantes: matorral, pastizal y cultivos, que no son tan evidentes en el análisis visual de los resultados.

3. Técnicas de análisis multitemporal

3.1. El factor tiempo en los estudios de teledetección espacial

Una de las aportaciones más destacadas de la teledetección espacial al estudio del medio ambiente es su capacidad para seguir procesos dinámicos. Al tratarse de información adquirida por un sensor situado en una órbita estable y repetitiva, las imágenes de satélite constituyen una fuente valiosísima para estudiar los cambios que se producen en la superficie terrestre, ya sean debidos al ciclo estacional de las cubiertas, y a catástrofes naturales o a alteraciones de origen humano.

En el seguimiento de la dinámica de un determinado fenómeno conviene distinguir dos aspectos relacionados con el cambio (Rodin, 1998): por un lado, la rapidez con que el fenómeno se produce, y por otro la pervivencia del cambio que implica (fig. 7.57). El primer aspecto hace referencia a la escala temporal en la que se manifiesta un fenómeno o, dicho de otra forma, a su duración en el tiempo. En este sentido, el rango de los fenómenos ambientales que se estudian en teledetección puede ir desde unas pocas horas (ciclones tropicales, terremotos, erupciones volcánicas) hasta varios años (desertificación, crecimiento urbano). El segundo aspecto se relaciona con la permanencia de los efectos de esa perturbación, que también puede variar en un ciclo de pocos días hasta varios años. El efecto de una inundación puede ser breve, si ésta fue superficial, o bastante permanente, si ha supuesto la modificación de algunos rasgos geomorfológicos (deslizamientos, por ejemplo). En definitiva, la pervivencia de los efectos y la duración del fenómeno no tienen por qué estar relacionados, o, dicho de otro modo, un fenómeno de corta duración puede tener una larga continuidad y viceversa.

TABLA 7.11. *Inventario de la ocupación del suelo en la imagen Torre100 de acuerdo a dos criterios de clasificación*

	Clasificación de máxima probabilidad			*Clasificación por RNA*		
	Píxeles	*Hectáreas*	*%*	*Píxeles*	*Hectáreas*	*%*
Urbano	110.553	6.909,56	13,27	67.365	4.210,31	8,08
Pastizal	178.735	11.170,94	21,45	226.811	14.175,69	27,22
Matorral	275.265	17.204,06	33,03	380.854	23.803,38	45,71
Pinar-encinar	9.839	614,94	1,18	16.766	1.047,88	2,01
Suelo	9.133	570,81	1,10	12.150	759,38	1,46
Cultivo	236.848	14.803,00	28,42	97.519	6.094,94	11,70
Agua	12.907	806,69	1,55	31.815	1.988,44	3,82
TOTAL	833.280	52.080,00	100,00	833.280	52.080,00	100,00

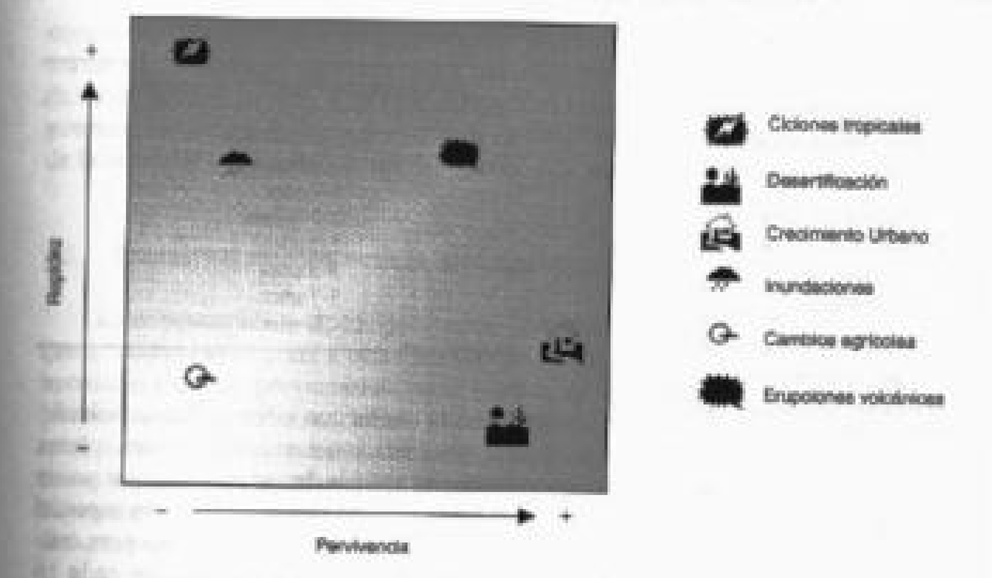


FIG. 7.57. *Escalas temporales de cambio para algunos fenómenos ambientales.*

La frecuencia más idónea para observar un determinado fenómeno dependerá de ambas variables: duración y pervivencia. Algunos procesos requieren una observación prácticamente continua, como puede ser la cartografía de nubes, mientras para otros bastará un inventario anual (cultivos) o quinquenal (cobertura del suelo). La tabla 7.12 presenta algunas cadencias de observación recomendables, según los fenómenos que se pretenda observar (Jensen *et al.*, 1983).

Como ya hemos visto, la frecuencia de observación depende de las características orbitales y anchura del área observada por el sensor, si bien en términos prácticos ese período se alarga si consideramos la cobertura nubosa o carencias del sistema sensor (falta de antenas receptoras, fallos en la adquisición o transmisión). Los sistemas actuales de teledetección proporcionan una amplia variedad de cadencias de observación, desde pocos minutos para los satélites meteorológicos de órbita geo-estacionaria y amplia cobertura, hasta varias semanas para los de recursos naturales, con órbitas más bajas y cobertura territorial mucho más limitada. Si en los primeros años de la teledetección, la resolución espacial del sensor se consideraba el elemento más crítico para valorar su potencialidad, la cobertura temporal cada vez se califica como un crite-

TABLA 7.12. *Cadencia de actualización para estudios multitemporales*

Fenómeno	*Período de observación recomendable*
Dinámica atmosférica	15-30 minutos
Seguimiento de desastres	2-24 horas
Evaluación de desastres	1-7 días
Predicción de cosechas	2-3 meses
Análisis de la deforestación	1-3 años
Actualización de mapas de cobertura	3-5 años
Dinámica urbana	5-7 años
Actualización de mapas topográficos	10-20 años

rio más protagonista, al subrayarse la necesidad de contar con información suficientemente actualizada. Por ejemplo, para evaluar las condiciones vegetales a corto plazo, de cara a predecir el rendimiento de un cultivo o el peligro de incendios —por poner dos ejemplos de gran interés territorial—, de nada serviría una alta precisión espacial sin el adecuado ciclo de cobertura. Un fino detalle espacial no es suficiente para estimar operativamente el riesgo de incendio si sólo contamos con una imagen cada 16 días. Será preferible, en este contexto, emplear imágenes menos detalladas, siempre que proporcionen información más frecuente.

Para que puedan abordarse estudios multitemporales con teledetección es preciso que el sistema sensor proporcione una cobertura periódica, en las mismas bandas espectrales, y con condiciones de observación similares (altura, hora, ángulo de adquisición). Estos requisitos los cumplen la mayor parte de los satélites de recursos naturales, excepción hecha de los sensores instalados sobre el *Space Shuttle* que no ofrecen una cadencia y homogeneidad adecuadas, si bien permiten comparaciones visuales-cualitativas de gran interés. Éste es también el caso de los sensores aerotransportados, singularmente de la fotografía aérea, que se ha utilizado profusamente para analizar la dinámica de la cobertura del suelo (Martínez Vega, 1989).

Como ya vimos en el capítulo 5, la dimensión temporal puede considerarse en teledetección con un doble objetivo: multiestacional y multianual (Chuvieco, 1998). En el primer caso, la dimensión temporal sirve para refinar la discriminación de algunas categorías, que pueden no ser separables espectralmente, pero sí atendiendo a su variedad fenológica. Con este objetivo se seleccionan imágenes adquiridas en distintas estaciones, de acuerdo al calendario fenológico de esas cubiertas. Habitualmente se combinan las bandas de todas las imágenes en un solo archivo, de tal manera que se enriquezca la clasificación espectral incorporando un componente temporal (Lo *et al.*, 1986). También hay ejemplos de comparación entre clasificaciones realizadas para distintas estaciones, comparando las categorías que en cada una se pueden separar (Schriever y Congalton, 1995). Los resultados suelen mejorar notablemente la clasificación mono-temporal (Girard, 1981; Mergerson, 1981), siempre que exista un buen ajuste geométrico entre fechas.

El segundo enfoque, que hemos denominado análisis multianual, tiene por objetivo detectar los cambios producidos entre dos o más fechas, para lo que suele partirse de imágenes adquiridas en distintos años, que se comparan visual o digitalmente (Gopal y Woodcock, 1996; Lucas *et al.*, 1993; Sader y Winne, 1992). En este caso, por contraposición al enfoque multiestacional, se procura que las imágenes sean de la misma época del año, con objeto de aislar más fácilmente lo que las imágenes manifiestan de cambios en el terreno. Con este objetivo, el análisis multianual requiere una homogeneización radiométrica y geométrica de las imágenes para minimizar la influencia de la atmósfera, las condiciones del sensor, o la geometría de iluminación.

3.2. Requisitos previos para el análisis multitemporal

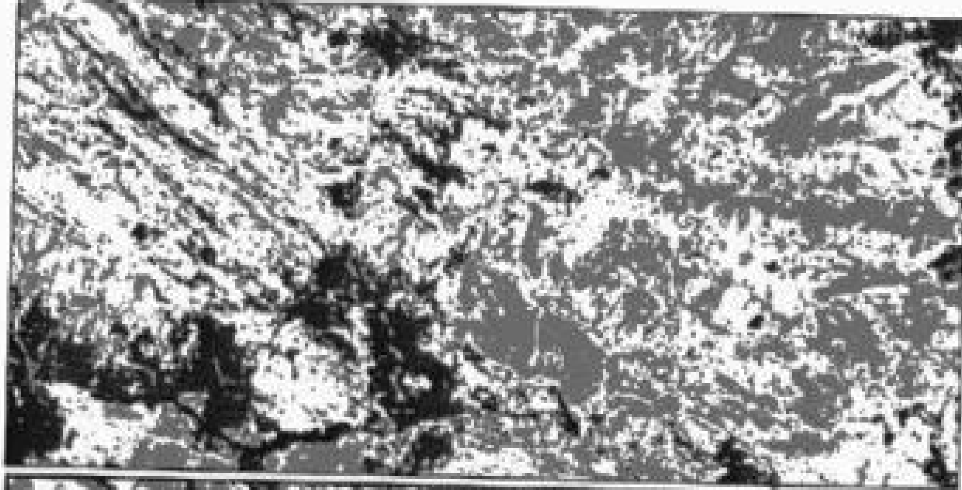
La comparación multitemporal entre imágenes se realiza, en la mayor parte de los casos, comparando píxel a píxel los ND de las distintas fechas. En consecuencia, es necesario eliminar previamente, en la medida de lo posible, cualquier cambio en los ND de la escena que no sea debido a cambios reales en la cubierta. Esto implica asegurar que estemos situados en la misma zona para ambas fechas, y que la variable que estamos comparando se refiera a la misma escala de medida. En definitiva, la comparación temporal requiere una previa corrección geométrica y radiométrica de las imágenes que estamos cotejando.

3.2.1. *Ajuste geométrico*

Para la comparación multitemporal es preciso que las imágenes se ajusten con gran nivel de detalle, ya que de otro modo estaríamos detectando como transformaciones lo que sería sólo fruto de una falta de ajuste entre imágenes. El efecto puede llegar a ser muy grave, especialmente cuando se trata de detectar categorías con una gran variabilidad espacial, como es el caso de las urbanas (Gordon, 1980), dependiendo también de la resolución espacial del sensor (Nelson y Grebowsky, 1982; Roy, 2000). Para sensores de baja resolución espacial se ha comprobado que hasta un 50 % del cambio observado entre dos imágenes puede deberse a errores de superposición cuando el ajuste entre imágenes tiene un error superior a 1 píxel (Townshend *et al.*, 1992). Varios autores han demostrado que se requieren precisiones de ajuste superiores a 0,2 píxeles para asegurar un error inferior al 10 % en la comparación multitemporal (Dai y Khorram, 1998; Townshend *et al.*, 1992).

Para ilustrar este tema hemos realizado un sencillo ejercicio, simulando el cambio en una clasificación de coberturas después de aplicarle un desplazamiento intencional. La clasificación corresponde a una imagen Landsat-TM sobre una zona forestal de la provincia de Valencia. Para simplificar las cosas incluye únicamente cuatro categorías. La clasificación original se desplazó un píxel hacia el oeste y el sur, generándose posteriormente una tabulación cruzada con la clasificación inicial. Como es lógico, en este caso todo el cambio observado en ese cruce resulta debido exclusivamente al desplazamiento geométrico que hemos introducido. Como podemos observar en la figura 7.58 y tabla 7.13*a*, ese porcentaje de cambio «ficticio» es bastante notable, alcanzando el 34 % del total del área de la imagen.

Menos severa resultaría la comparación entre clasificaciones que tuvieran algún tipo de generalización previa, ya que se eliminarían pequeños grupos aislados que introducen mayor ruido cuando existe ese desplazamiento. Por esta razón hemos realizado la misma comparación entre la clasificación original y la desplazada, des-



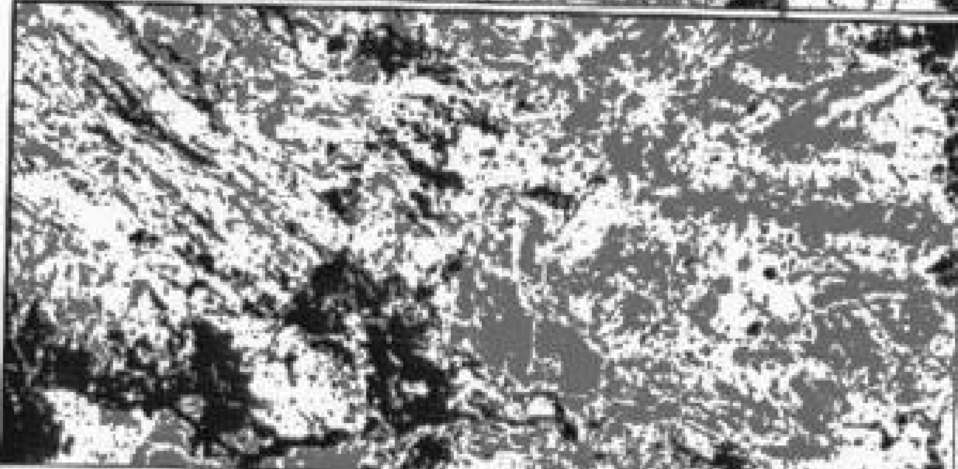


FIG. 7.58. *En la parte superior, clasificación de cobertura del suelo utilizada como ejemplo. En la inferior, la misma clasificación con un desplazamiento sistemático.*

pués de aplicarles a ambas un filtro modal de 5 × 5 píxeles. En este caso, los desplazamientos son mucho menos severos, alcanzando el 19 % de la imagen (tabla 7.13*b*). Si bien los desplazamientos reales entre imágenes no serán tan sistemáticos como los aquí indicados, el ejercicio nos sirve para entender la importancia de conseguir un ajuste muy preciso entre imágenes, de cara a garantizar la eficacia de la comparación multitemporal. La idea de generalizar las imágenes antes de compararlas resulta evidentemente una precaución a tener en cuenta. Algunos autores han propuesto incluso comparar imágenes previamente segmentadas, de tal forma que se comparen parcelas de una cobertura homogénea en lugar de píxeles individuales (Bruzzone y Fernández-Prieto, 2000).

Como ya indicamos en el anterior capítulo, la mayor parte de las imágenes basan el ajuste geométrico en la localización de una serie de puntos de control imagen-mapa.

TABLA 7.13*a*. *Efecto del desajuste geométrico para la comparación multitemporal. Datos originales*

		Imagen desplazada				
		1	*2*	*3*	*4*	*Total*
Imagen original	1	94	247	42	6	389
	2	251	20.653	9.315	897	31.116
	3	43	9.512	51.449	15.337	76.341
	4	3	755	15.560	27.897	44.215
	TOTAL	391	31.167	76.336	44.137	152.061

TABLA 7.13*b*. *Datos filtrados (filtro modal de 5 × 5 píxeles)**

		Imagen desplazada				
		1	*2*	*3*	*4*	*Total*
Imagen original	1	98	100	30	41	269
	2	132	23.556	4.954	387	29.029
	3	39	5.196	66.982	8.681	80.898
	4	0	259	8.962	32.361	41.582
	TOTAL	269	29.111	80.928	41.470	151.778

* La no coincidencia en los totales con la tabla anterior se debe a que no se consideran en ambos casos los píxeles con clase 0, fruto del desplazamiento.

Para el análisis multitemporal, los puntos se toman entre imágenes, eligiendo una como referencia. En este caso, el proceso de seleccionar puntos comunes resulta más sencillo, ya que son muchos más los rasgos comunes entre dos imágenes, que entre una imagen y un mapa. Para dos imágenes pueden emplearse formas características de la vegetación, del trazado parcelario o la hidrografía, visibles entre imágenes pero que habitualmente no son localizables en el mapa, además de caminos o carreteras. Elegir unos u otros elementos de referencia dependerá, lógicamente, de la resolución espacial de la imagen.

También para el análisis multitemporal resulta de interés el proceso de selección semi-automática de puntos de control. A partir de ventanas móviles en torno a cada punto localizado en la imagen de referencia, el punto en la homóloga se obtiene por correlación entre los ND de las dos imágenes (Díez de Arribas y Nicolás, 2001; Ortí *et al.*, 1979).

3.2.2. *Homogeneización radiométrica*

Otro importante problema en la detección de cambios es el producido por las variaciones que introducen las condiciones de observación, situaciones atmosféricas o la calibración del sensor. Estos efectos modifican la signatura espectral de un píxel, aunque se mantenga constante la cubierta. En consecuencia, es preciso homogeneizar los

ND de las imágenes que intervienen en el análisis. Para ello puede optarse por un doble enfoque:

1. Calibrar los ND de modo absoluto, convirtiéndolos a medidas de reflectividad o temperatura del suelo.
2. Equiparar los ND entre imágenes.

En el primer caso es preciso acudir a los modelos de conversión a parámetros físicos vistos previamente, incorporando los parámetros de corrección atmosférica y de iluminación más propios para cada fecha. En el segundo enfoque basta una corrección relativa entre fechas, ya que sólo se trata de facilitar las comparaciones entre ellas. Con esta óptica, los métodos de corrección propuestos se basan en situar una serie de píxeles de radiancia constante entre fechas, preferiblemente que recojan áreas de baja reflectividad (sombras, aguas claras y profundas) y alta reflectividad (suelos descubiertos, estacionamientos, pistas de aterrizaje). A partir de los ND de esos píxeles pueden estimarse unos coeficientes de sesgo y ganancia, para cada banda, que permitan corresponder los ND entre fechas distintas. El método se ensayó con buenos resultados en un estudio multitemporal sobre la Albufera de Valencia (Caselles y López, 1989), comparándolo con modelos atmosféricos estándar (Tanre *et al.*, 1986). La viabilidad de estas correcciones para homogeneizar las condiciones atmosféricas entre imágenes también se ha demostrado en el marco de la estimación de cosechas (Hill y Sturm, 1991) y en el inventario forestal (Coppin y Bauer, 1994), facilitando ajustes con una correlación superior a 0,98 (Coppin y Bauer, 1994; Hall *et al.*, 1991*a*).

Puesto que la variación temporal entre píxeles puede alterar esos coeficientes de regresión, otros autores han propuesto utilizar los ND más oscuros y más claros entre fechas, obtenidos a partir de los componentes de brillo y verdor de la transformación *tasseled cap* (7.1.3):

$$ND_{c,k} = s_k ND_k + g_k \qquad [7.48]$$

esto es el ND corregido en la banda *k* se estimaría a partir de unos coeficientes de sesgo y ganancia para esa banda, que se obtienen a partir de:

$$s_k = (ND_{cl,r,k} - ND_{os,r,k}) / (ND_{cl,c,k} - ND_{os,c,k}) \qquad [7.49]$$

y

$$g_k = (ND_{os,c,k} ND_{cl,r,k} - ND_{os,r,k} ND_{cl,c,k}) / (ND_{cl,c,k} - ND_{os,c,k}) \qquad [7.50]$$

donde $ND_{os,r,k}$ y $ND_{cl,r,k}$ indican el ND medio de los píxeles más oscuros y más claros, respectivamente, de la imagen de referencia, y $ND_{os,c,k}$ y $ND_{cl,c,k}$ lo mismo en la imagen a corregir. El método se comprobó muy sólido para homogeneizar el efecto atmosférico entre imágenes para un estudio multitemporal. Caso de que la imagen de referencia se hubiera corregido atmosféricamente, el método también sirve para eliminar el aporte atmosférico en las imágenes de otras fechas, obteniendo coeficientes de correlación muy adecuados con correcciones atmosféricas de precisión (Hall *et al.*, 1991*a*). Otros

autores proponen, en ausencia de superficies invariantes entre fechas, utilizar aquellos que cuenten con NDVI más bajos y más altos (Hill y Sturm, 1991).

Recientemente se ha propuesto un método de corrección multitemporal que ha intentado estandarizar los procedimientos de ajuste entre imágenes (Heo y Fitzhugh, 2000). En primer lugar se establecen unos criterios bastante estrictos para seleccionar las superficies como invariantes entre fechas. Debe tratarse de áreas con la misma elevación, para que el espesor atmosférico sea similar; con similar topografía, preferentemente plana, para que los ángulos de iluminación entre fechas sean similares; con poca vegetación, para minimizar los efectos de los cambios fenológicos; que mantengan el patrón espacial, y que recojan un amplio rango de ND para que la regresión sea consistente. Los autores proponen eliminar puntos con residuales muy altos, pues puede tratarse de áreas de cambio o afectadas por algún tipo de ruido, y contemplan la posibilidad de utilizar distintos puntos en cada banda para considerar el distinto sesgo que puedan incluir. Sugieren utilizar píxeles concretos en lugar de promedios de ventanas de 3 × 3 píxeles.

3.3. Técnicas para el análisis estacional

Cuando el fin último del análisis temporal es determinar perfiles estaciones en las cubiertas vegetales de interés, habitualmente la interpretación se realiza sobre las distintas fechas de modo simultáneo. Por ejemplo, si se pretende mejorar la clasificación de un determinado cultivo se acude a imágenes de momentos clave dentro de su ciclo fenológico, que permitan separarlo con nitidez de otros cultivos espectralmente similares (Prados, 1995). La clasificación, en este sentido, se realiza con todas las fechas simultáneamente, ya que se pretende caracterizar una categoría a partir de curvas espectro-temporales.

Una muestra sencilla de este enfoque sería la discriminación entre cultivos de secano, de regadío y suelos en barbecho (fig. 7.59). En una imagen de verano, será senci-

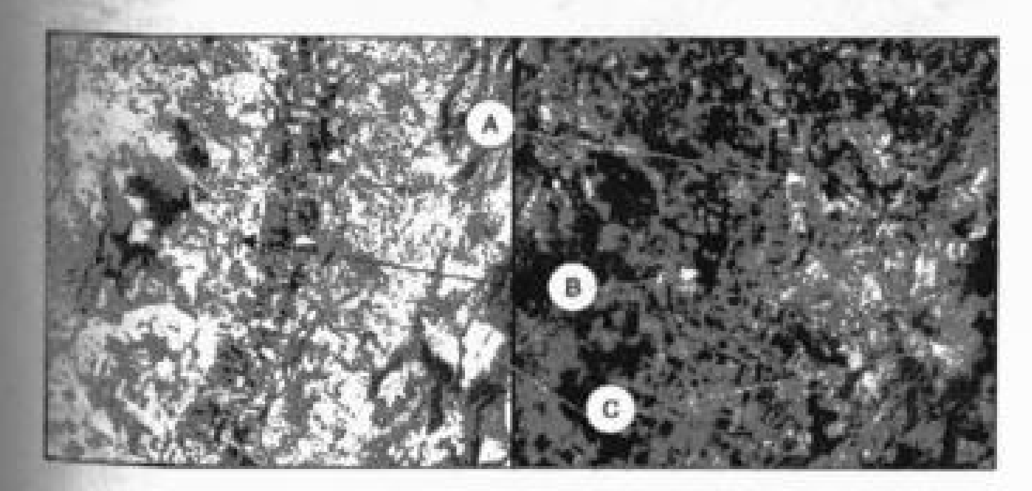


FIG. 7.59. *Fragmento de dos imágenes TM del valle del Henares (Guadalajara) tomadas en agosto (izqda.) y mayo (dcha.).*

llo separar los cultivos regados (*A*), pero no tanto las parcelas con cultivos de secano (*B*) y las que descansan (*C*), lo que sí es factible en la primavera, aunque en esa fecha no resulte tan clara la separación entre secano y regadío. En consecuencia, será conveniente utilizar las dos fechas de modo integrado.

Como el incremento en el número de fechas implica aumentar el volumen de cálculo, ha sido bastante frecuente aplicar previamente alguna técnica de compactación, como el análisis de componentes principales o los índices de vegetación. De esa forma pueden procesarse sólo las bandas con mayor contenido informativo, evitando redundancias innecesarias (Joly *et al.*, 1983; Maselli *et al.*, 1996).

Un aspecto específico del análisis estacional es el seguimiento de las condiciones ambientales en un ciclo corto de tiempo. En este ámbito entraría el análisis de fenómenos atmosféricos o de las condiciones vitales de la vegetación, por ejemplo de cara a estimar demandas de riego, predicciones de rendimientos o situaciones de peligro de incendios. Por ejemplo, la figura 18* muestra dos imágenes de primavera y verano sobre el sector central del P. N. Cabañeros, mostrándose el contraste estacional que experimentan las especies herbáceas dominantes en el valle. Este análisis estacional puede abordarse con pocas imágenes (p. ej., una por estación), o con una serie más numerosa, intentando recoger las variaciones temporales de ciclo inmediato. Éste es el caso de emplear imágenes AVHRR, que se adquieren diariamente, y permiten reconstruir con más detalle las tendencias del crecimiento o senescencia de las comunidades vegetales (Millington *et al.*, 1994). La figura 7.60 muestra un serie de imágenes del NDVI de Andalucía para la primavera y el verano de 1994, que permiten analizar la evolución estacional de esta variable, así como las variaciones espaciales de esa evolución.

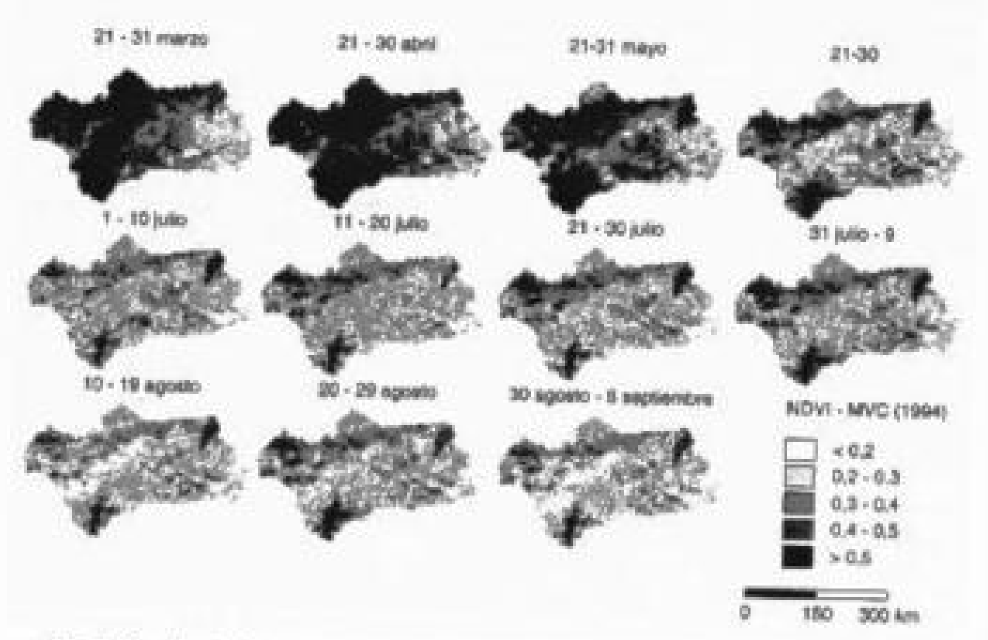


FIG. 7.60. *Variación estacional del NDVI para la región de Andalucía en la primavera y el verano de 1994.* (Alonso *et al.*, 1996.)

Cuando se trabaja con este enfoque de alta resolución temporal lo más frecuente es procesar imágenes de satélites meteorológicos, ya que proporcionan la mejor resolución temporal, a un coste aceptable para conseguir series largas de datos. Lógicamente, su baja resolución limita el análisis a escalas regionales o globales, si bien la gran información temporal puede compensar la carencia de detalle espacial para reconocer ciertos tipos de cubiertas vegetales. Gracias a ello, pueden plantearse clasificaciones con cierto nivel de detalle temático, a partir de las series multitemporales (Loveland *et al.*, 1991; Tucker *et al.*, 1985). La integración de estas imágenes con información meteorológica puede enriquecer notablemente nuestro conocimiento sobre la actividad fisiológica de las plantas, de cara a mejorar los modelos existentes de productividad vegetal (Chladil y Nunez, 1995; Nemani *et al.*, 1993), o plantear estimaciones de su estado hídrico (como ya vimos en 7.1.1.3).

Frecuentemente, en el análisis de estas series suelen emplearse índices relativos, que permiten medir las condiciones de un momento frente a una tendencia tipo, ya sea el máximo anual o un promedio de una serie larga. Uno de los más sencillos es el verdor *(greenness)*, definido como (Kogan, 1990):

$$\mathrm{VERDOR}_i = \frac{\mathrm{NDVI}_i - \mathrm{NDVI}_{min}}{\mathrm{NDVI}_{max} - \mathrm{NDVI}_{min}} \cdot 100 \qquad [7.51]$$

donde NDVI_i indica el valor del índice de vegetación para el período *i*, y NDVI_{max} y NDVI_{min} los valores máximos y mínimos de los índices en cada píxel para la serie de imágenes analizada. El verdor, en principio, está más relacionado que el NDVI absoluto con los cambios debidos a las condiciones atmosféricas, ya que se enfatiza el cambio temporal en el vigor y densidad vegetal frente al cambio espacial que también está incluido en el valor absoluto del NDVI. Esa variación temporal se considera precisamente en función de los umbrales de variación propios de cada píxel. Este índice se ha comprobado de gran interés en la estimación del peligro de incendios (Burgan *et al.*, 1998) o condiciones de sequía (Peters *et al.*, 1991).

También se ha propuesto calcular el decremento temporal de los índices de vegetación, de cara a medir el efecto acumulado de las variaciones estacionales en el vigor vegetal. Una manera sencilla de obtener este índice es calcular la pendiente de la línea que define la evolución temporal del índice (Illera *et al.*, 1996):

$$PT_i = \frac{\sum_{i=1,n}(\mathrm{NDVI}(t_i) - \mathrm{NDVI}(t_{i-1}))}{t_i - t_{i-1}} \qquad [7.52]$$

donde PT_i indica la pendiente del período *i*, y t_i el período de tiempo considerado. Este índice parece bastante relacionado con las variaciones del vigor vegetal desde la primavera hasta el verano, identificando situaciones de deterioro en la vegetación (López *et al.*, 1991).

De forma similar, también puede estimarse la desviación de una serie de imágenes respecto al valor medio de ese período, en una serie previa de varios años:

$$\Delta t_i = \frac{\text{NDVI}(t_i)}{\text{NDVI}(\bar{i})} \cdot 100 \qquad [7.53]$$

donde NDVI(t) indicaría el valor del índice correspondiente a un determinado período i y NDVI($\bar{i}$) el valor medio para ese período, para un conjunto de años suficientemente representativo. Esto permitiría ver si las tendencias de un momento determinado son las esperables o se registran valores anómalos (ya sean superiores o inferiores a la tendencia promedio).

Otra técnica utilizada para series temporales de imágenes es el ACP. En este caso, los primeros componentes de una serie normalmente indican una situación promedio, la tendencia estable, mientras los componentes secundarios informan sobre aspectos del cambio que se observe en el período. A partir de componentes principales estandarizados se abordó un interesante análisis de las tendencias de la vegetación en África, sobre una serie temporal de 36 imágenes que cubrían todo el continente. Se observó que los primeros componentes recogían la tendencia promedio, mientras los restantes marcaban algunos rasgos de interés en la fenología de la vegetación, detectando eventos anómalos de sequía, e incluso algunos errores en la adquisición de las imágenes, difícilmente detectables sobre los valores originales (Eastman y Fulk, 1993).

3.4. Técnicas para la detección de cambios

Los estudios de detección de cambios pueden aplicarse a una gran variedad de disciplinas (Mouat *et al.*, 1993). Tienen por objeto analizar qué rasgos presentes en un determinado territorio se han modificado entre dos o más fechas. Como en otras fases de la interpretación de imágenes, la localización de esos cambios suele implicar un compromiso entre los errores de omisión y de comisión, esto es desechar un cambio que realmente existe, o detectar un cambio que no ha ocurrido, respectivamente. En el primer caso tendríamos un carencia de información y en el segundo una falsa alarma. La importancia de uno u otro tipo de errores marcará, en buena medida, la técnica más conveniente a utilizar en cada caso. En algunos estudios, el objetivo preferente será evitar las falsas alarmas (aplicar tratamientos sobre un cultivo que no está afectado por una plaga, por ejemplo), pero lo más habitual será poner más bien el énfasis en reducir las omisiones (por ejemplo, resulta preferible asistir a una zona que no ha sido realmente afectada por una inundación, que arriesgarse a que no se atiendan algunas efectivamente dañadas).

Otro aspecto de interés en el análisis de cambios hace referencia al tipo de transformaciones que pretenden delimitarse en una imagen, según se transformen los rasgos espectrales o espaciales de una imagen (Robin, 1998). Los primeros son los que se detectan más habitualmente en teledetección y hacen referencia a modificaciones en la señal reflejada o emitida por una determinada parcela, ya sea como consecuencia de cambios en la cubierta, ya debido a alteraciones en su densidad o estado fenológico. Por ejemplo, un nuevo cultivo en la misma explotación implica mantener la estructura espacial pero alterando la respuesta espectral. Por su parte, los cambios espaciales implican transformaciones de la forma o el tamaño de las parcelas, aunque pueda mante-

nerse su cobertura previa (por ejemplo, igual cultivo sobre una parcela más grande o pequeña). Estos últimos están menos desarrollados en teledetección, pero se están comenzando a analizar gracias a las técnicas de segmentación multitemporal (Bruzzone y Fernández-Prieto, 2000; Smits y Annoni, 1999).

Intentando resumir la amplia relación de estudios que utilizan técnicas de análisis multitemporal (Chuvieco, 1998; Eastman *et al.*, 1994; Jensen, 1981; Mouat *et al.*, 1993; Singh, 1986), podemos establecer dos grupos, según utilicen imágenes continuas o categorizadas. En el primer caso se emplean técnicas cuantitativas: diferencias, regresión, componentes principales, etc., mientras en el segundo se comparan imágenes previamente clasificadas, mediante tablas de contingencia. A continuación vamos a repasar las técnicas más empleadas, presentando algunos ejemplos prácticos de su utilización.

3.4.1. *Composiciones de color multitemporales*

En esta técnica se trata de detectar las áreas de cambio mediante el análisis visual de imágenes en color provenientes de varias fechas. Ya hemos visto en esta obra que cualquier sistema de ADI permite obtener mezclas en color de tres bandas de una imagen, aplicando a cada una de ellas uno de los cañones de color disponibles (R,V,A). Si la imagen resultante aparece en tonos de color es debido a que las tres bandas que se combinan presentan comportamientos espectrales diferentes. Dicho de otra manera, si vemos un píxel en color es porque cuenta con un ND distinto en las tres bandas que estamos utilizando (o al menos en dos de ellas), ya que de otra manera se vería en tonos de gris.

Si en lugar de combinar tres bandas distintas del espectro mezclamos tres fechas de la misma banda estaríamos viendo en tonos de color aquellos píxeles que tuvieran distintos ND en alguna de ellas, mientras aparecerían en tonos de gris los que no hubieran cambiado entre fechas. La interpretación del color resultante dependerá, lógicamente, de qué bandas combinemos y en qué orden temporal. Para una composición de dos fechas resulta frecuente que se aplique el cañón rojo a la primera fecha y el verde a la segunda, dejando el azul vacío o repitiendo la segunda fecha (fig. 19*), así se simplificaría la interpretación del color resultante. Con este criterio aparecerían en tonos grises las áreas estables, en rojos las zonas que hayan reducido su ND entre las dos fechas y en cian (V + A) las que lo hayan ganado. El sentido de la transformación que muestren esos colores dependerá de qué bandas estemos comparando entre fechas. En caso de que estemos combinando el NDVI de los dos períodos (manteniendo el criterio de rojo a la primera fecha y verde + azul a la segunda), los tonos rojos revelarían decrementos de NDVI (en definitiva, pérdidas de cobertura vegetal debidas a talas, cosechas, incendios, etc.), mientras los cian indicarían aumentos de NDVI (ganancias de vegetación, por ejemplo, a causa de la puesta en cultivo de suelos previamente descubiertos o por desecación de una lámina de agua). Lógicamente, también pueden usarse los ND originales o los valores de reflectividad de alguna de las bandas de la imagen. En ese caso, la interpretación diferirá de la indicada para el NDVI.

La tabla 7.14 recoge un ejemplo de posible interpretación cruzada entre composiciones multitemporales en color de dos bandas distintas (la IRC y SWIR). Como puede analizarse, los incrementos o decrementos en una banda tendrán significados dis-

TABLA 7.14. *Modelo de interpretación para dos composiciones multitemporales en el IRC y el SWIR*

Banda espectral		IRC Color en pantalla		
		Tonos rojos	*Tonos verdes*	*Tonos amarillos*
SWIR Color en pantalla	*Tonos rojos*	Suelo a agua	Suelo a vegetación	Suelo seco a húmedo
	Tonos verdes	Vegetación a suelo	Agua a suelo	Suelo húmedo a seco
	Tonos amarillos	Vegetación senescente	Vegetación emergente	Sin cambios

(Los tonos corresponden a lo que se observaría en una composición multitemporal de cada banda, asumiendo que el color rojo se aplica a la primera fecha y el verde a la segunda.)

tintos según las tendencias observadas en otra/otras. Por lo demás, el método resulta bastante sencillo y tiene la ventaja de incorporar el conocimiento y los criterios de análisis del intérprete, lo que resulta muy ventajoso en categorías urbanas (Martin, 1989; Sader y Winne, 1992).

Un ejemplo de estas composiciones en color multitemporal aparecen en la figura 19*, mostrando las tendencias del crecimiento urbano de Madrid entre 1984 y 2000. Los tonos cian indican superficies en construcción, ya sea por nuevas infraestructuras (M-45, trazado del AVE, aeropuerto) o expansiones residenciales (bastante evidentes al norte del núcleo urbano, así como algunos sectores del Este.

3.4.2. *Diferencia entre imágenes*

Una simple resta entre las imágenes de dos fechas, previamente homogeneizadas radiométrica y geométricamente, permite discriminar aquellas zonas que han experimentado cambios entre esas fechas. Las zonas estables presentarán un valor cercano a cero, mientras las que hayan experimentado cambios ofrecerán valores significativamente distintos a cero (positivos o negativos). Si el equipo de ADI no permite visualizar valores negativos conviene añadir al cálculo una constante para evitar éstos. En resumen:

$$ND_c = N_{t2} - ND_{t1} + C \qquad [7.54]$$

donde ND_c indica el ND correspondiente a la imagen de cambios, ND_{t1} y ND_{t2} los correspondientes a las imágenes del primer y segundo período, respectivamente, y C es una constante para evitar valores negativos.

Como fruto de este cálculo se obtiene una imagen de cambios, que presentará valores bajos o negativos (tonos oscuros) para las zonas que hayan reducido su ND, mientras los más altos (tonos claros) corresponderán a aquellas que hayan ganado y los intermedios indicarán zonas estables. El cálculo puede realizarse sobre los ND de alguna de las bandas originales (en ocasiones se ha utilizado la banda roja: Pilon *et al.*, 1988), aunque es más frecuente aplicar esta operación sobre índices de vegetación. En este caso, el valor de la diferencia nos permite señalar las zonas que han perdido o ganado vigor vegetal, o simplemente la que han cambiado su cobertura por efecto de la rotuación, talas o incendios (Coppin y Bauer, 1994; Martín y Chuvieco, 1995). El histograma de esa imagen de cambios suele revelar un perfil gausiano, con las máximas

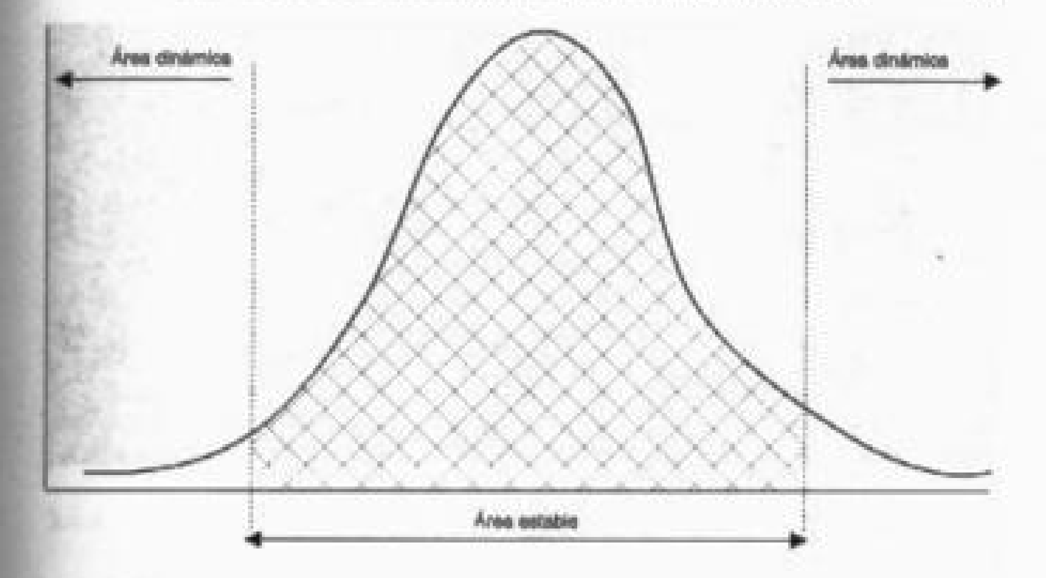


FIG. 7.61. *Histograma teórico de una imagen de cambios.*

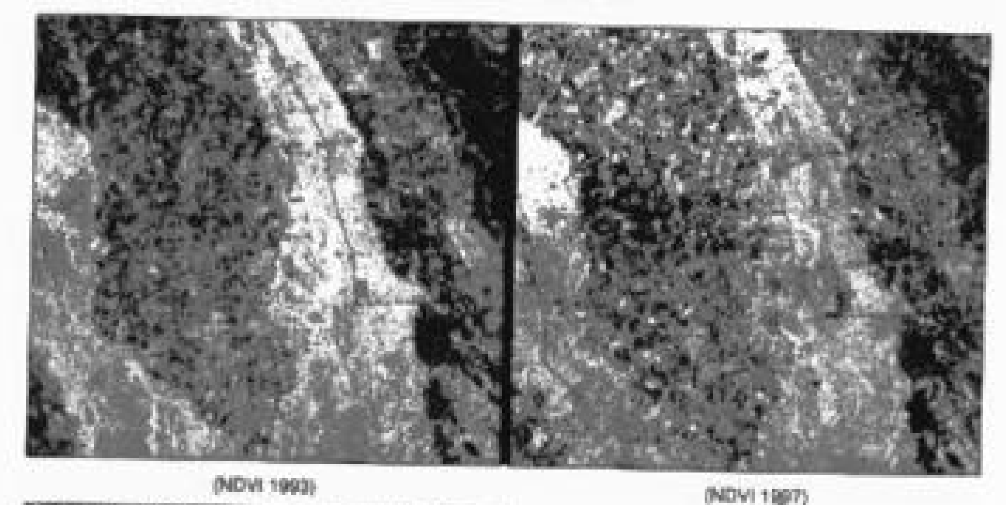
frecuencias para las zonas estables (en el centro del histograma) y las dinámicas ocupando las colas de la distribución (fig. 7.61).

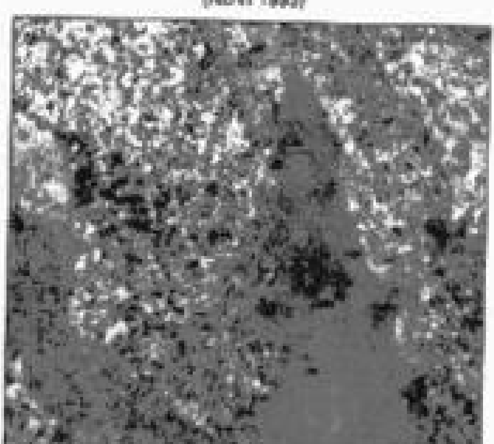
Las figuras 7.62 y 7.63 incluyen dos ejemplos del empleo de esta técnica para detectar cambios en la vegetación. En ambos casos se incluye el NDVI como variable de entrada. El primer ejemplo, tomado de un estudio de deforestación en los Llanos Occidentales venezolanos (Vargas, 2000), revela las zonas que han perdido cubierta forestal entre 1993 y 1997, período de especial intensidad de este fenómeno. Por su parte, la figura 7.63 muestra la diferencia entre imágenes de NDVI adquiridas antes y después de un incendio en el interior de Valencia (próxima a Buñol). Se observa en tonos oscuros las zonas donde el decremento de NDVI ha sido más intenso, que coincide bastante bien con las zonas quemadas, mientras los grises medios corresponden a zonas que no han alterado su cubierta vegetal entre ambas fechas.

3.4.3. *Cocientes multitemporales*

La diferencia entre imágenes resulta una técnica sencilla para observar cambios entre fechas, si bien tiene el problema de reflejar únicamente las diferencias absolutas, pero no ofrece la significación del cambio frente a los valores originales. Por ejemplo, una reducción de 20 ND entre fechas puede significar una alteración significativa si el ND original era 40, mientras resultará menos importante si el ND de la primera fecha era de 200. Para subsanar ese problema puede ser más conveniente en ocasiones emplear cocientes multitemporales, que ofrecen una valoración relativa del cambio:

$$ND_c = (ND_{t2} / ND_{t1}) \times C \qquad [7.55]$$





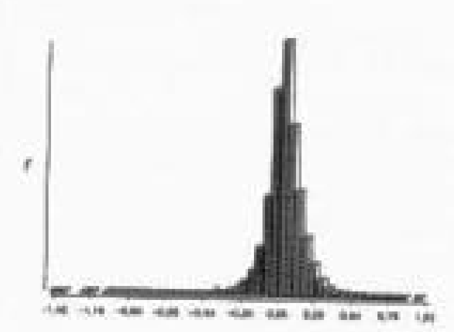


FIG. 7.62. *Diferencias entre NDVI de 1997 y 1993 para detectar procesos de deforestación.*

con el mismo significado de la fórmula anterior, o también los índices multitemporales normalizados:

$$ND_{i,j} = (((ND_{i2} - ND_{i1}) / (ND_{i2} + ND_{i1})) + 1) \times 127 \qquad [7.56]$$

en este caso se añade al índice 1 y se multiplica el resultado por 127 para escalar el resultado entre 0 y 254.

Los cocientes multitemporales se han empleado en inventarios agrícolas (Lo *et al.*, 1986; Mussakowski, 1985) y forestales (Howarth y Wickware, 1981; Singh, 1986). En aplicaciones ambientales es frecuente que estos cocientes se calculen a partir de los índices de vegetación, lo que permite simplificar la variación vegetal en una sola banda. En este contexto se han empleado con gran éxito los cocientes en estudios de deforestación

(Grover *et al.*, 1995; Singh, 1986; Vargas, 2000), e incendios forestales (Kasischke *et al.*, 1993; Martín y Chuvieco, 1995).

El principal problema de los cocientes multitemporales es su carácter no simétrico. En otras palabras, el resultado es dependiente de qué fecha elijamos para el numerador. Una reducción a la mitad del ND (p. ej., de 100 a 50) ofrece un valor de 2 o de 0,5 según el orden en que introduzcamos las fechas. En definitiva, implica una transformación no lineal de las relaciones temporales. Para solucionar este problema, algunos autores recomiendan realizar una conversión logarítmica del resultado (Eastman *et al.*, 1994).

La figura 7.63*b* nos ofrece una imagen del cociente normalizado de los NDVI correspondientes al incendio de Buñol, junto a la imagen de diferencias simples. En este caso, la delimitación del área quemada es bastante clara y similar en ambas técnicas, observándose tanto el perímetro propiamente dicho, como sectores dentro de la mancha quemada donde el incendio fue menos severo o había menor presencia vegetal.

3.4.4. *Componentes principales*

Como antes señalamos, en el caso de aplicaciones multitemporales el ACP se utiliza de un modo un tanto particular, ya que no se pretende retener la información común entre fechas, sino precisamente la que cambia. Para aplicar esta técnica en la detección de cambios se genera un archivo multitemporal con las bandas correspondientes a las dos fechas, sobre el que se aplica el ACP. En este caso, los primeros componentes resultantes del análisis no son los más interesantes, ya que recogerán la dimensión de estabilidad en la imagen. Por su parte, los componentes secundarios ofrecen la información no común: el cambio, que es precisamente lo que más interesa en este contexto.

El ACP se ha utilizado frecuentemente en detección de cambios. Para 2 imágenes MSS (4 bandas cada una) se ha comprobado que los componentes 3, 4 y 5 recogen ha-

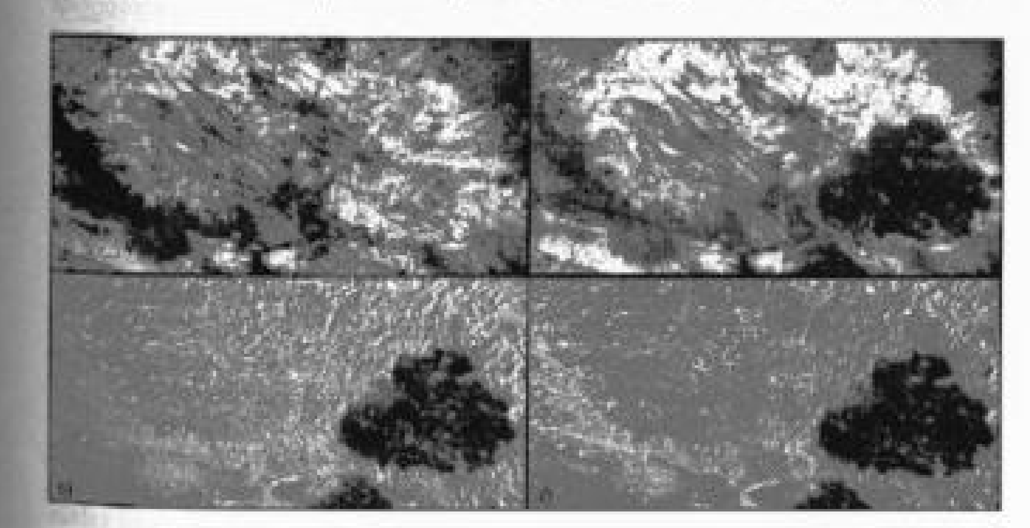


FIG. 7.63. *Imágenes de NDVI antes (a) y después del fuego (b) en el área de Buñol. Diferencias (c) y cocientes (d) entre ambas imágenes, que evidencian el área quemada.*

TABLA 7.15. *Autovectores de los componentes principales para las imágenes de Torrelaguna (TM = 1984; ETM = 2000)*

	Autovalor	Varianza	TM1	TM2	TM4	TM5	TM7	ETM1	ETM2	ETM4	ETM5	ETM7
1	2.045,73	70,71 %	0,193	0,153	0,305	0,623	0,281	0,087	0,129	0,376	0,386	0,256
2	350,64	12,12 %	–0,145	–0,113	–0,264	–0,460	–0,245	0,126	0,180	0,380	0,527	0,392
3	285,31	9,86 %	–0,097	–0,038	0,238	–0,075	–0,215	–0,167	–0,141	0,766	–0,210	–0,449
4	88,63	3,06 %	–0,365	–0,271	–0,648	0,394	0,220	–0,248	–0,261	0,106	0,122	–0,116

bitualmente el cambio entre fechas (Byrne *et al.*, 1980). Algunos autores interpretan que los dos primeros componentes de ese conjunto de 8 ofrecen información sobre el brillo y el verdor estables en la imagen, mientras el 3.° indica cambio en el brillo y el 4.° cambio en el verdor (Fung y LeDrew, 1987; Fung y LeDrew, 1988; Ingebritsen y Lyon, 1985). También en ocasiones se han comparado los componentes principales deducidos para cada fecha, por separado, aplicando una diferencia o cociente entre ellos (Coppin y Bauer, 1994; Singh, 1986).

En la tabla 7.15 aparecen los autovalores y autovectores correspondientes a la comparación multitemporal de dos imágenes adquiridas en el área de Torrelaguna, que venimos utilizando en este capítulo. Aquí se han mezclado las bandas 1, 2, 4, 5 y 7 de dos pequeñas ventanas extraídas de dos imágenes tomadas con 16 años de diferencia (verano de 1984 y primavera de 2000), por los sensores TM y ETM+, respectivamente.[8] Los cuatro primeros CP suman más del 95 % de la varianza, por lo que se puede afirmar que recogen lo más sustancial de ambas fechas. La interpretación de los componentes se realiza de forma similar a como comentamos en el epígrafe 1.4, si bien en este caso, además del contraste espectral que marquen los coeficientes también hay que observar el temporal. El primer CP corresponde claramente al sustrato común entre todas las bandas y las dos fechas, ya que todos los coeficientes son positivos, lo que podemos simplificar denominándolo «brillo estable». El segundo corresponde con nitidez al cambio entre fechas, ya que los coeficientes son negativos en la primera imagen y positivos en la segunda. Ya que no se hace una distinción entre bandas, dentro de cada fecha, podemos denominar a este componente como «cambios en el brillo», o mejor aún, considerando el signo de los coeficientes, «incremento de brillo». El tercero muestra para las dos fechas el contraste entre el IRC y las demás bandas, por lo que podemos calificarlo como «verdor estable». Nótese que los coeficientes son algo más altos en el IRC de la segunda fecha por tratarse de una imagen de primavera y, por tanto, contar con mayor vigor vegetal que en la primera. Finalmente, el cuarto componente resulta más complicado de interpretar, pues si bien se refiere a cambio entre fechas (los coeficientes tienen signos distintos en el IRC y en una de las bandas del SWIR), no es nítido a qué tipo de contraste especial está refiriéndose, tal vez a la transición de vegetación seca a vigorosa.

La figura 7.64 proporciona una valoración gráfica del sentido de estos componentes. Aparece en la parte superior la banda 4 de las dos fechas, para que se nos facilite la observación visual de los cambios. A continuación se sitúan los 4 primeros CP del

8. La banda 3 de la imagen TM de 1984 estaba dañada, por lo que no se ha podido utilizar en este análisis. No obstante, su variación espectral se cubre bastante bien con las bandas 2 y 1.

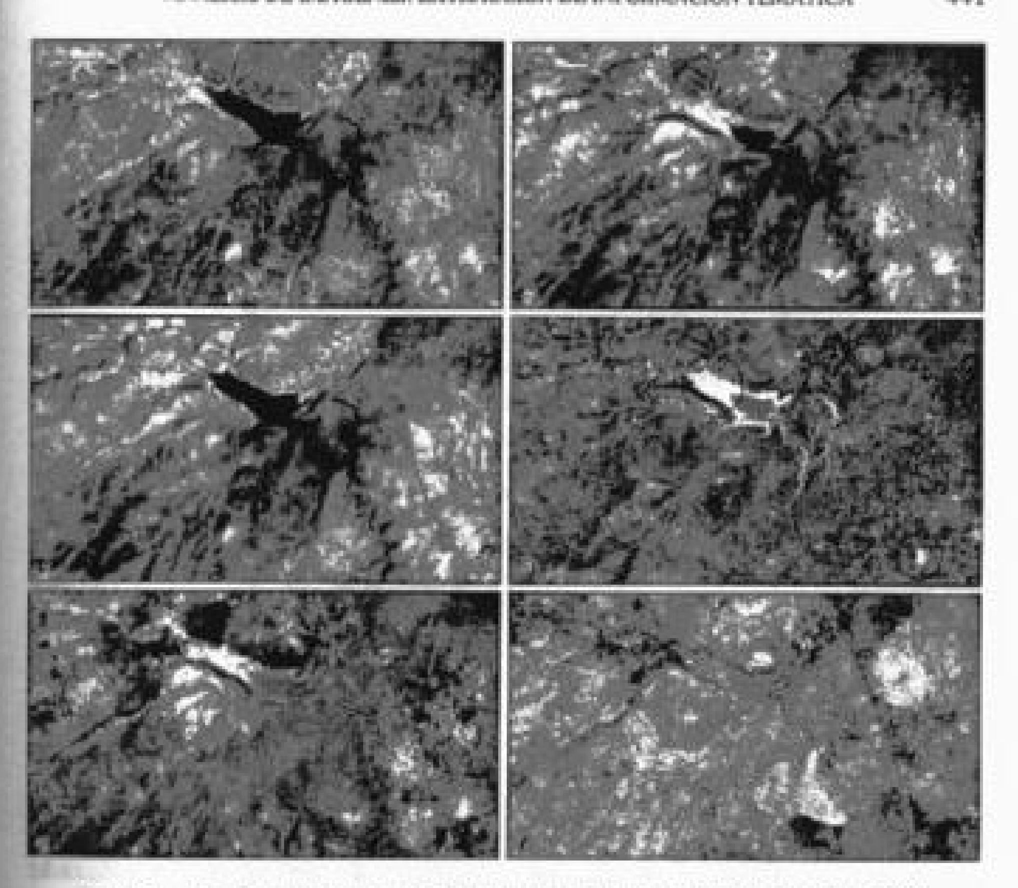


FIG. 7.64. *Imágenes originales de Torrelaguna: a) Banda 4, 1984; b) Banda 4, 2000. Cuatro primeros CP multitemporales (c, d, e, f) de ambas imágenes. En el segundo componente se observan algunos cambios en el brillo de la imagen.*

archivo multitemporal. Se confirma que el primero recoge la información estable a las dos fechas, con la excepción del sector del embalse del Vellón que aparece parcialmente desecado en la segunda fecha y no se aprecia en la imagen de estabilidad, posiblemente por el fuerte peso de la absorción del agua en la primera. En el segundo, que habíamos denominado «incremento de brillo», esa zona se observa con gran nitidez, ya que es precisamente la que presenta los valores más altos (mayor incremento de brillo entre las dos fechas, al pasar de agua a vegetación). Asimismo, hemos destacado con círculos dos recientes urbanizaciones en construcción (o recientemente construidas), que ofrecen valores más altos de brillo por pasar de vegetación a suelo construido. El tercer componente muestra los sectores de vegetación más vigorosa entre fechas, que corresponden generalmente a pastizales. Finalmente, el cuarto nos informa de cambios que se han producido en el vigor vegetal, de áreas de vegetación seca a vigorosa. Esta dimensión nos permite caracterizar con claridad algunas zonas residenciales ya consolidadas, que han pasado de vegetación arbórea-arbustiva a especies ornamentales, con mayor vigor, no obstante la interpretación de este componente, como hemos visto, resulta un tanto confusa.

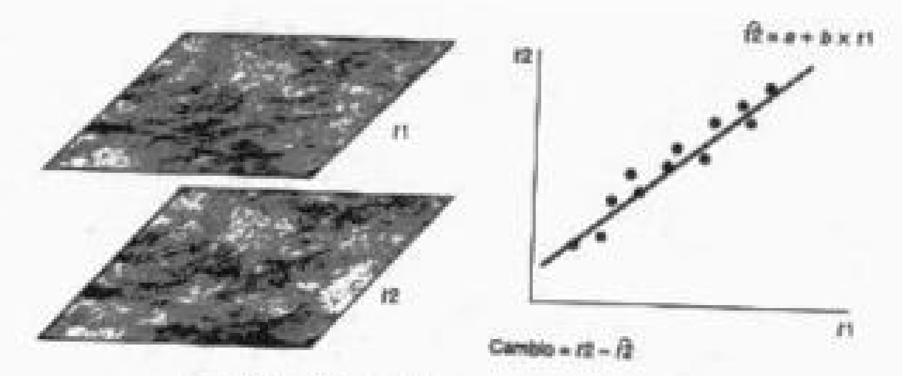


FIG. 7.65. *Esquema de la regresión multitemporal.*

3.4.5. *Regresión*

Como es bien sabido, las técnicas de regresión se emplean para estimar valores de una variable de interés a partir de otra que está fuertemente asociada con ella. Esa asociación se mide a partir de unas observaciones comunes a ambas variables, a partir de las cuales se ajusta una función que las relaciona numéricamente. En el marco de la corrección geométrica de imágenes ρ, ya tuvimos ocasión de comentar esta técnica, por lo que aquí sólo nos detendremos en su aplicación al análisis de cambios.

En este contexto, las técnicas de regresión se utilizan para estimar cuáles serían los ND de la imagen de la segunda fecha caso de que no hubiera habido cambios entre ellas. En definitiva, se considera que la segunda fecha es una función de la primera, y que toda desviación de la función estimada estaría representando el cambio. Siguiendo la notación convencional, los ND de la segunda fecha se estiman a partir de la primera, utilizando:

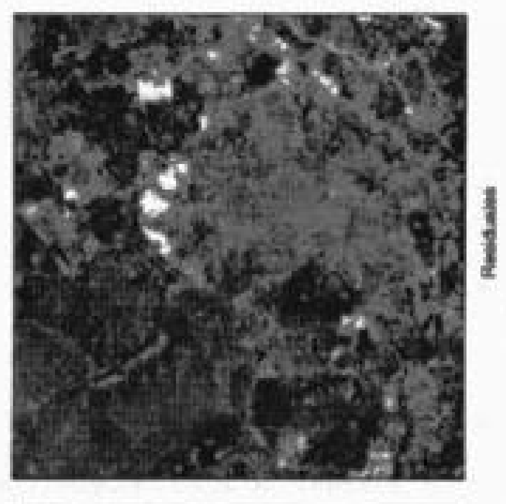
$$\hat{ND}_{t2} = a + b \cdot ND_{t1} \qquad [7.57]$$

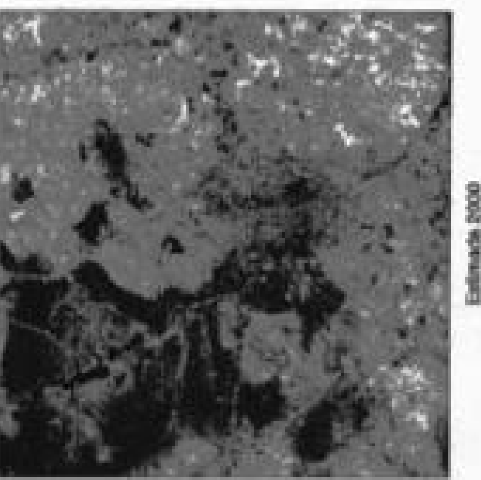
donde $\hat{ND}_{t2}$ estaría indicando el valor estimado de la segunda fecha (*t*2), calculado a partir de los coeficientes de regresión (*a*, *b*) sobre los ND de la primera fecha (*t*1). Estos valores estimados serán muy similares a los reales de la segunda fecha, siempre que no se haya producido cambio, sirviendo además para homogeneizar la radiometría entre las dos fechas. En caso de que hayan ocurrido cambios entre imágenes, los ND reales de la segunda fecha presentarán valores alejados de los estimados por la regresión, o lo que es lo mismo contarán con altos residuales:

$$ND_{c} = ND_{t2} - \hat{ND}_{t2} \qquad [7.58]$$

Los coeficientes de regresión pueden calcularse para todos los ND de la imagen o a partir de un muestreo. En el primer caso, puede violentarse algún requisito de la regresión, ya que los ND presentan una clara autocorrelación espacial (Congalton, 1988*a*; Eastman *et al.*, 1994), además de complicar los cálculos. La regresión multitemporal se ha utilizado para determinar cambios en áreas urbanas (Molina y Chuvieco, 1997), y forestales (Martín y Chuvieco, 1995; Vargas y Chuvieco, 1991), con buenos resultados.

Un ejemplo de la aplicación de este tipo de técnicas aparece en la figura 7.66 que





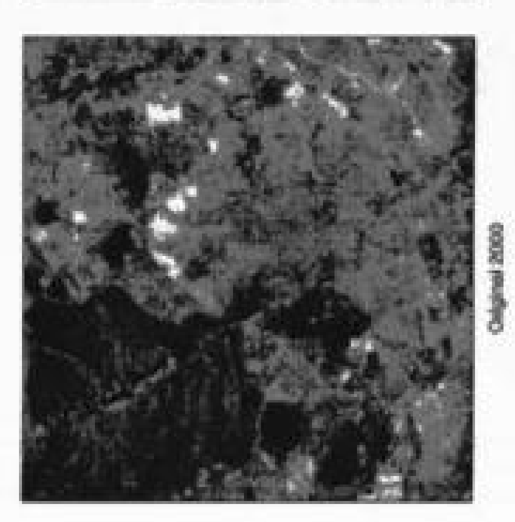


FIG. 7.66. *Regresión multitemporal sobre las imágenes de Madrid.*

muestra una comparación entre la banda ETM+3 de una imagen de Madrid adquirida en marzo de 2000 y la estimada a partir de la TM-3 de agosto de 1992, así como la imagen de residuales. Se observan con claridad los desarrollos urbanos que han ocurrido en esta ciudad a lo largo de la última década, principalmente la ampliación del aeropuerto de Barajas (al NE), la urbanización de los sectores comprendidos entre la M-30 y la M-40 al norte de la ciudad y la construcción de la M-45 y la línea de alta velocidad Madrid-Barcelona, ambos al este de la ciudad.

En el caso de la imagen de Torrelaguna, la regresión entre la banda 2 de las dos fechas facilitó un coeficiente de determinación (r^2) de 63,38 % con la siguiente regresión:

$$ND_{t2} = 13{,}436 + 0{,}584 \cdot ND_{t1}$$

Esta función se ha aplicado para obtener la imagen estimada de la segunda fecha (en este caso de 2000), que se ha restado de la imagen original para obtener los residuales. Esta imagen de residuales nos informa de los principales cambios producidos, tanto en su intensidad (valor), como su sentido (signo). Se observan nuevas áreas residenciales, al Este, Norte y Centro de la imagen, así como la pérdida de buena parte del área embalsada en el Vellón.

La figura 7.67 recoge la aplicación de la misma técnica a la misma ventana de

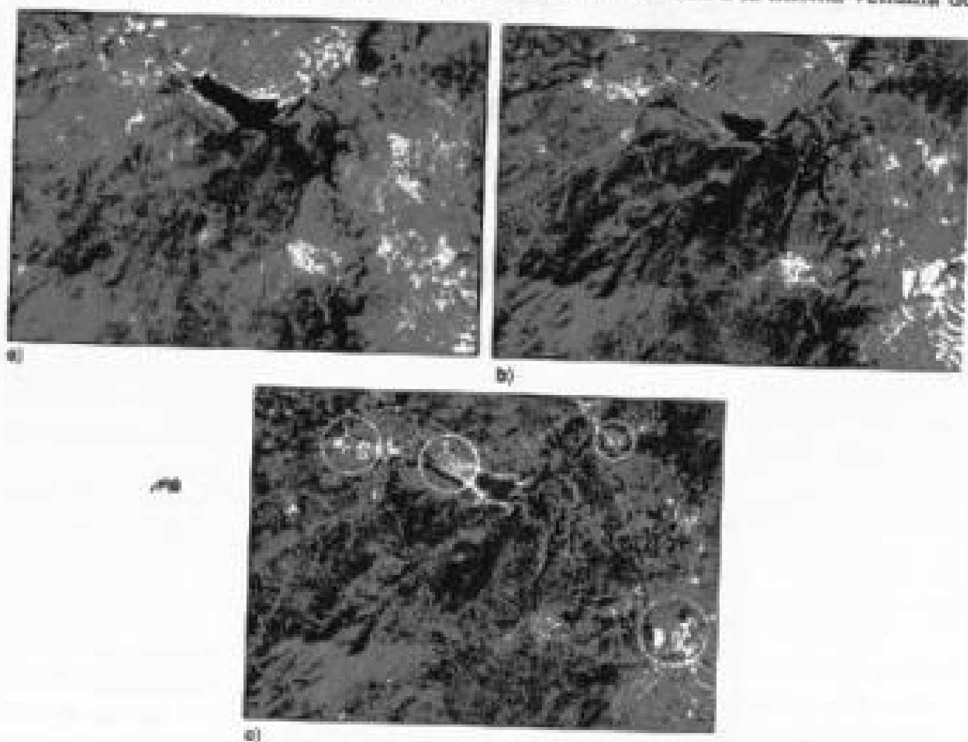


FIG. 7.67. *Regresión multitemporal de la imagen de Torrelaguna: a) banda TM2 1992; b) banda ETM2 2000; c) imagen de residuales. Se señalan con círculos los cambios más evidentes.*

la imagen Torrel00 que hemos analizado a través del ACP. De nuevo se observa en la imagen de residuales los cambios más destacados entre fechas: alteraciones del nivel del agua, crecimiento urbano de Guadalix y apertura de nuevas urbanizaciones.

3.4.6. *Vectores multitemporales*

Es una técnica que intenta incorporar no sólo la importancia, sino también la dirección del cambio entre imágenes. Si representamos en un eje bivariado dos bandas originales (por ejemplo, la rojo e infrarrojo cercano), cada píxel viene definido por un punto (localización de sus ND en las dos bandas). Si ese píxel cambia su cobertura entre dos fechas, también modificará su emplazamiento espectral. La magnitud del cambio vendrá dado por la longitud del vector que separa ambos puntos. Por su parte, el sentido del cambio se define por el ángulo que forma con el eje de referencia (fig. 7.68). Caso de que el píxel haya reducido el vigor vegetal, tenderá a disminuir su ND en el infrarrojo cercano y aumentarlo en el rojo. En consecuencia, el vector presentará una dirección descendente y hacia la derecha del gráfico (en términos geográficos tendría dirección SE). Por el contrario, si aumentara su cobertura vegetal el vector presentaría una dirección NW.

Con este sencillo ejemplo, podemos introducir el interés de este tipo de análisis para la detección de cambios, ya que nos ofrece una imagen de su magnitud y sentido. La intensidad del cambio se identifica con la longitud del eje, que puede obtenerse a

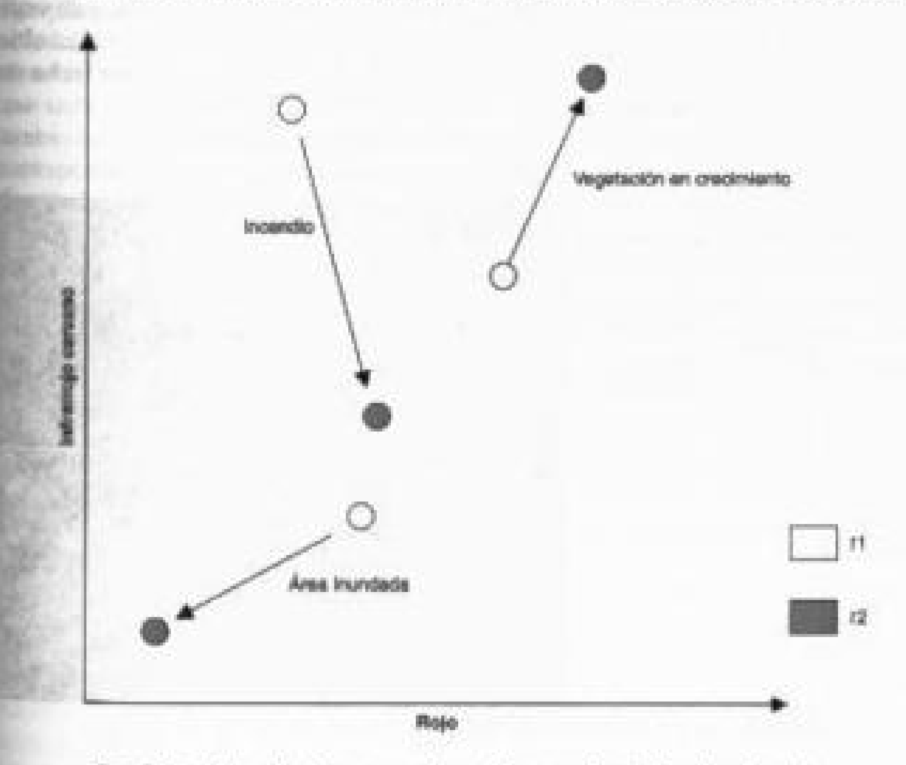


FIG. 7.68. *Ejemplo de vectores de cambio entre dos fechas de referencia.*

1992; Fung y LeDrew, 1988). Los límites idóneos variaban con cada técnica de detección utilizada, si bien se encontraban en torno a una desviación típica de la media. Ese límite puede considerarse estadísticamente razonable, pero no sabemos si el resultado es extrapolable a otra zona o a otro tipo de aplicación.

Más recientemente se ha propuesto ajustar los umbrales de cambio considerando la función señal/ruido de un determinado sensor. Ese ruido puede provenir del incorrecto ajuste entre fechas, o de la propia radiometría del sensor. Se propone estimarlo a partir de una biblioteca de imágenes históricas de cambio, que permitan delimitar los umbrales de evidencia más apropiados para ese tipo de imágenes. Para un estudio de cambios urbanos con imágenes SPOT-P, los autores utilizan una biblioteca con 711 pares de cambios, extraídos de imágenes del mismo sensor para distintas zonas y fechas (Smits y Annoni, 2000).

Un segundo criterio parte de señalar umbrales de cambio a partir de valores críticos de incremento o decremento de una determinada variable física. Por ejemplo, puede dictaminarse que una disminución de temperatura superior a 10 °C entre dos imágenes tomadas en días consecutivos indicaría la presencia de nubes en la segunda imagen, o que un decremento mayor de un cierto umbral de NDVI manifiesta un cambio abrupto en la vegetación que sólo puede deberse a un tránsito de vegetación a suelo. Éste ha sido de hecho un criterio habitual para delimitar áreas quemadas a partir de imágenes TM y AVHRR (Martín y Chuvieco, 1995). El valor específico de esos umbrales puede derivarse a partir de medidas de laboratorio tomadas con espectro-radiómetro.

También puede optarse por señalar umbrales de cambio adaptados al entorno, aplicando técnicas de contexto espacial. Por ejemplo, pueden determinarse como cambios aquellos píxeles que superen un cierto umbral de desviaciones típicas sobre el cambio observado en una ventana que les circunde. Esto es lo que se denomina desviación frente a la tendencia *(departure from background)*, y es una técnica bastante utilizada para detección de incendios activos (Flasse y Ceccato, 1996) y delimitación de áreas quemadas (Fernández *et al.*, 1997).

Finalmente, se pueden seleccionar los umbrales de cambio a partir de una clasificación de las imágenes de cambio obtenidas con distintas técnicas, con objeto de establecer grupos homogéneos de píxeles estables y dinámicos. Pueden realizarse clasificaciones supervisadas, a partir de áreas que se conozcan como estables o dinámicas, o no supervisadas, dejando al programa que seleccione los grupos naturales presentes en esas imágenes. El criterio ha dado buenos resultados en aplicaciones forestales (Coppin y Bauer, 1994) —clasificando imágenes de cambio generadas a partir de la transformación *tasseled cap*, índices de vegetación y análisis de componentes principales—, y urbanas (Wang, 1993), en este caso sobre las bandas originales de las dos fechas.

Sea uno u otro el criterio que se utilice, conviene recordar que la mayor o menor rigidez de los umbrales implicará incrementar o disminuir los errores de omisión, o inversamente los de comisión, por lo que el usuario tendrá que decidir en primer lugar qué tipo de error resulta más tolerable. Volviendo al ejemplo de la delimitación de áreas quemadas, los umbrales muy exigentes reducirían las áreas no quemadas que se discriminen como tales, a la vez que aumentarían los píxeles realmente quemados que no se detectarían con ese algoritmo (fig. 7.71). En este caso concreto, pensamos que resulta más ade-

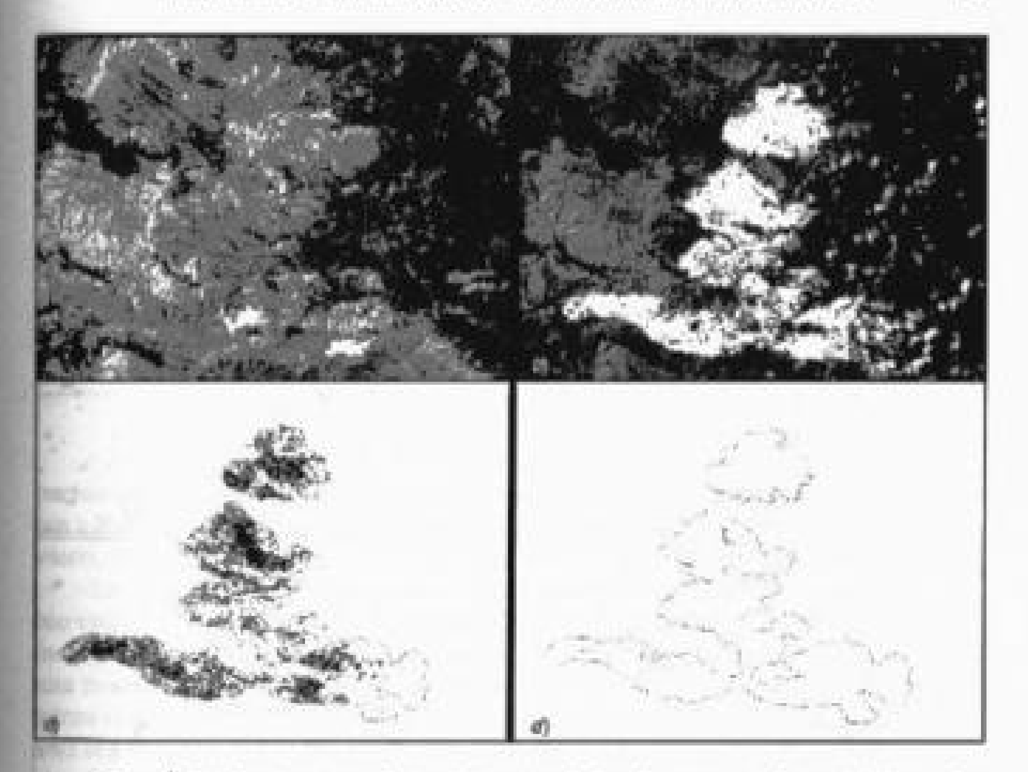


FIG. 7.71. *Índice de área quemada para la imagen de Buñol, antes (a) y después del incendio (b). Aplicación de umbrales laxos (c) y estrictos (d) para discriminar área quemada.*

cuado optar por la segunda opción, de cara a reducir los errores de comisión, y aplicar posteriormente un algoritmo de contexto para delimitar con mayor nitidez las áreas realmente quemadas. Otro aspecto interesante en la delimitación de umbrales es el carácter fragmentario que puede tener la imagen resultante, ya que los límites se establecen por cortes en el histograma de cambios y no por criterios espaciales. Para solventar este problema puede resultar conveniente aplicar algún filtro modal a las imágenes resultantes (fig. 7.72) o eliminar aquellos grupos de píxeles que sean más pequeños de un determinado tamaño (Fernández-Gustiz, 2001).

3.4.8. *Análisis multitemporal de imágenes clasificadas*

La detección de cambios puede también abordarse empleando las técnicas de clasificación antes comentadas. En este caso, no se presenta el problema de delimitar umbrales, ya que clasificar lleva consigo discretizar la escala continua de las imágenes originales, por tanto comparaciones multitemporales se realizan entre categorías.

La detección de cambios a partir de técnicas de clasificación puede abordarse empleando dos grupos de técnicas: 1) por un lado, comparar imágenes previamente clasificadas, y 2) por otro, clasificar conjuntamente las imágenes de las dos fechas.

En el primer caso se aborda una clasificación para cada imagen por separado, cuidando de emplear la misma leyenda temática en las dos fechas, con objeto de que

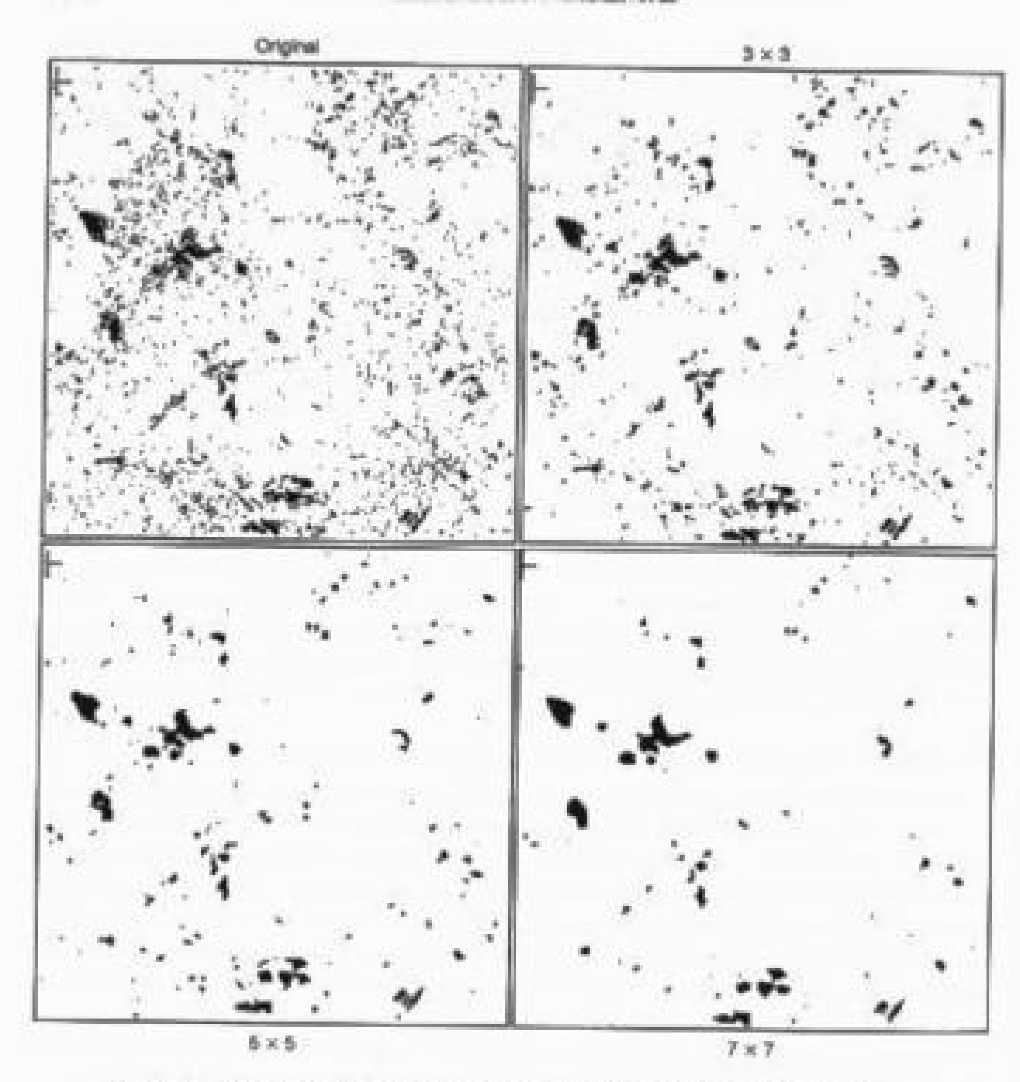


FIG. 7.72. *El empleo de filtros modales restringe las áreas de cambio detectadas entre imágenes.* (Fernández, 2001.)

puedan compararse posteriormente. A continuación se genera una tabla multitemporal de cambios, en donde se presentan las transiciones que se producen entre las dos fechas (tabla 7.16). En la diagonal de esta tabla aparecen los píxeles estables (que cuentan con la misma categoría en las dos fechas), mientras los cambios se detectan en el resto de las celdillas. El gran interés de esta tabla es ofrecernos las transiciones que se han producido. En otras palabras, no sólo observamos las zonas estables y dinámicas, sino también cuál era la cobertura original y cuál la actual, lo que nos indica las tendencias del cambio en la zona de estudio. En un estudio de deforestación, esto nos permitiría conocer qué tipo de especies forestales están siendo más afectadas; en una evaluación de incendios, qué especies se han quemado, o en un estudio urbano, qué es-

TABLA 7.16. *Cambios urbanos en la ciudad de Madrid a través del análisis de dos imágenes Landsat-TM y ETM (en hectáreas)*

		1990						
		Vegetación	Matorral-pastizal	Secano*	Suelos	Áreas urbanas	Agua	Total
2000	Vegetación	10.773,38	4.681,44	666,31	77,81	1.669,19	14,13	17.884,25
	Matorral-pastizal	793,31	5.188,75	5.924,94	346,38	1.605,44	5,50	13.864,31
	Secano	468,63	2.566,81	2.507,44	130,50	456,88	1,25	6.131,50
	Suelo	134,63	1.182,69	3.992,75	816,06	950,94	1,00	7.078,06
	Áreas urbanas	1.209,56	1.778,81	2.034,63	603,13	7.475,31	3,13	13.104,56
	Agua	60,50	9,00	9,50	5,31	19,81	151,44	255,56
	TOTAL	13.442,00	13.407,50	15.135,56	1.979,19	12.177,56	176,44	58.318,25

* La imagen de 2000 se tomó en primavera, de ahí algunos cambios en cada categoría entre las dos fechas. Fernández (2001).

pacios están experimentado un mayor proceso de urbanización (Adeniyi, 1985; Coppin y Bauer, 1994; Howarth y Boasson, 1983; Jakubauskas *et al.*, 1990; Molina y Chuvieco, 1997).

En este sentido, puede aplicarse algún estadístico para medir el grado de cambio entre las dos fechas, a partir de calcular su grado de asociación. Por ejemplo, el índice Kappa —que permite calcular el grado de acuerdo entre filas y columnas de una matriz cuadrada, como luego veremos en el contexto de la verificación de imágenes (cap. 8)— permite medir el grado de cambio entre las dos fechas: cuanto más alto sea el valor, indicaría una mayor estabilidad.

En un análisis posterior podría analizarse el origen de estos cambios, acudiendo a información auxiliar almacenada en un SIG. Por ejemplo, abandonos de tierras podrían explicarse por factores relacionados con la productividad del suelo, con la topografía o con la accesibilidad (Bosque *et al.*, 1991).

El principal problema de esta tabla es su gran dependencia de la fiabilidad de las clasificaciones individuales. En otras palabras, si las clases no se han discriminado correctamente en cualquiera de las dos fechas, los cruces entre categorías resultarán erróneos, ofreciendo una información imprecisa del cambio. En cualquier caso, la fiabilidad de la tabla multitemporal siempre es inferior a las fiabilidades de cada clasificación.[9] El empleo de técnicas de clasificación borrosa puede paliar algunos de estos errores, ya que ciertas transiciones imposibles (p. ej., de urbano a rural) pueden solventarse observando el grado de pertenencia de cada píxel a esas categorías en las dos fechas (Wang, 1993). Este enfoque «borroso» en el análisis temporal resulta especialmente beneficioso cuando pretendemos analizar la dinámica de un fenómeno que presenta una distribución gradual en el espacio, como podría ser la densidad y estado de la vegetación (Foody, 2001).

Otro aspecto a considerar en la comparación entre clasificaciones afecta a la cartografía de resultados. Puesto que podemos encontrar cruces múltiples entre las categorías de las dos fechas, el número de clases a cartografiar puede ser bastante elevado. Por ejemplo, con una sencilla clasificación de 8 categorías por fecha tendríamos 64 clases

9. Concretamente es su producto. Si las clasificaciones individuales cuentan con una exactitud de 0,85 y 0,90, la fiabilidad de la multitemporal será de 0,85 × 0,90 = 0,76.

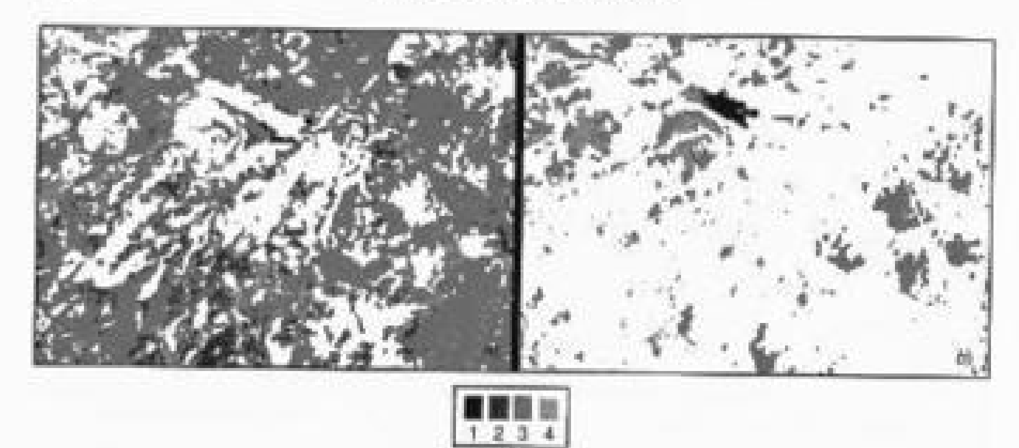


FIG. 7.73. *Ejemplo de cartografía dinámica sobre una ventana de Torrelaguna (1984-2000): a) procedencia del suelo; b) procedencia del pastizal. En ambos casos el 1 indica agua; el 2 matorral; el 3 pastizal y el 4 suelo descubierto. En blanco, se señalan las zonas estables.*

resultantes posibles. Aunque puede haber algunas de ellas que estén vacías (ya que hay cruces temporales prácticamente imposibles), la representación gráfica de esas concurrencias resulta bastante complicada. Una alternativa para representarlos sería recoger varios mapas del mismo cruce, por ejemplo uno por categoría de la segunda fecha, indicando con tramas o colores su origen en la primera fecha. Esto es lo que se presenta en la figura 7.73, que recoge la dinámica de dos categorías entre 1984 y 2000 en una ventana de la zona de Torrelaguna. Los tonos blancos indican zonas estables y los de gris señalan cuál es la cobertura de la primera fecha. En consecuencia, pueden observarse tanto las áreas estables, como las transiciones que se han producido entre las dos imágenes.

El otro enfoque de la clasificación multitemporal considera la asignación conjunta de las dos fechas. En este caso, la clasificación resultante estará formada por categorías multitemporales, definidas por su estabilidad o por su cambio entre las dos imágenes que se consideren. Nombres apropiados a estas clases podrían ser, por ejemplo, «transición de zonas rurales a urbanas», «cambios de agricultura de secano a regadío», o «urbano estable». Esas clases pueden deducirse de una clasificación supervisada, en donde el intérprete señale como áreas de entrenamiento aquellos sectores que hayan experimentado las transformaciones más interesantes. Esa leyenda de trabajo, por tanto, tiene que ser dinámica, incluyendo categorías de estabilidad y de cambio (por ejemplo, áreas que eran rurales en la primera fecha y pasaron a urbanas en la segunda, o zonas de cultivo estable). También puede optarse por la clasificación no supervisada, donde el algoritmo de agrupación identificará los grupos de estabilidad y cambio más importantes de la imagen, quedando luego al intérprete la tarea de asignar esos grupos a categorías multitemporales significativas. En este caso, la fiabilidad de la comparación temporal no depende de la obtenida en cada imagen, sino que se mide sobre la clasificación resultante, ya que las dos fechas se agrupan conjuntamente. Algunos trabajos recientes señalan el interés de realizar estas comparaciones temporales no supervisadas incluyendo explícitamente el componente textural, de cara a obtener productos más robustos espacialmente (Bruzzone y Fernández-Prieto, 2000).

4. Determinación de la estructura espacial del territorio: la imagen como mosaico paisajístico

4.1. TELEDETECCIÓN Y ECOLOGÍA DEL PAISAJE

Frente a la óptica tradicional de la ecología de campo, preocupada por los análisis a escala de detalle, ha crecido en los últimos años el interés por extender estas observaciones a un marco más amplio, de tal forma que se incluya explícitamente la variación espacial en el análisis y gestión integral de ecosistemas. En este enfoque, la teledetección y los SIG pueden jugar un papel muy destacado, ya que son técnicas que permiten gestionar información georreferenciada, facilitando el análisis espacial de los datos, así como la obtención de variables críticas para un entendimiento más completo del medio ambiente (Hoffer, 1994; Wilkie y Finn, 1996).

Hemos visto en anteriores capítulos que el análisis de imágenes de satélite proporciona la distribución espacial de algunas variables que son claves para entender el funcionamiento de un ecosistema, como son la temperatura de superficie, la radiación interceptada por la vegetación, el contenido de clorofila o de agua en las hojas, o el índice de área foliar.

En este capítulo vamos a centrarnos en los métodos para obtener información sobre las relaciones espaciales entre los elementos que forman la imagen. Una imagen de satélite puede considerarse como una representación digital del mosaico que forma un determinado paisaje. Por tanto, a partir de estas imágenes pueden medirse las relaciones espaciales entre los elementos de ese mosaico, denominados, en ecología del paisaje, manchas o teselas *(patches)*. Al tratarse de una imagen digital pueden aplicarse sobre las bandas originales, sobre alguna transformación de ellas o sobre una imagen ya clasificada, medidas que permitan evaluar cómo se configuran las distintas cubiertas en un territorio concreto.

El patrón espacial con el que se presentan las diversas coberturas terrestres tiene gran interés para entender ciertos procesos ecológicos, como la dispersión de organismos, el uso de los recursos por parte de la fauna local (Congalton *et al.*, 1993*a*), la comunicación genética o la extensión espacial de ciertas alteraciones, como son las causadas por fuegos o plagas (Hargrove *et al.*, 2000; Muchoki, 1988; Sample, 1994), además de estar directamente relacionada con la biodiversidad (Roy y Tomar, 2000). Por ejemplo, la fragmentación espacial del paisaje, que está relacionada con la conectividad/aislamiento que presentan las distintas manchas, puede dificultar la migración de especies, lo que implica un deterioro, o incluso una desaparición de las mismas, al degradarse su composición genética (Griffiths *et al.*, 1993. De igual modo, la proximidad a carreteras o áreas agrícolas está relacionada con situaciones de desequilibrio, pues implica una alteración del número y/o tipo de especies que aparecen en esos bordes. Obviamente, esto no es aplicable por igual a cualquier especie, por lo que es preciso reforzar la investigación sobre las relaciones entre estructura espacial y funcionamiento de los ecosistemas. En consecuencia, la gestión integrada de los mismos implica contar con información no sólo sobre el tipo de cubiertas presentes en el territorio, sino también sobre su disposición espacial. La reciente tendencia a asegurar un «medio ambiente sostenible» implica considerar varios aspectos, como son minimizar la fragmentación del hábitat, mantener la biodiversidad, identificar y gestionar efectos

acumulativos, y analizar, predecir y vigilar impactos a varias escalas espaciales y temporales (Green, 1994; Haines-Yaung *et al.*, 1993; Quattrochi y Goodchild, 1997; Wilkie y Finn, 1996; Saura 2002).

El empleo de imágenes de satélite en ecología del paisaje tiene una historia reciente, pero ya cuenta con interesantes ejemplos (Gulinck *et al.*, 1991; Walsh *et al.*, 1998). En este campo la teledetección ofrece una visión sinóptica del paisaje, constituye un conjunto homogéneo de medidas y facilita el seguimiento multitemporal de fenómenos que afectan a la composición del territorio (Delbaere y Gulinck, 1995). De acuerdo a Walsh *et al.* (1998), la teledetección ofrece en este ámbito de trabajo las siguientes ventajas:

1. Permite verificar la composición del paisaje para unidades espaciales de información (píxeles), unidades biofísicas (p. ej., cuencas) y para su agregación espacial.
2. Ofrece una representación espacial de la estructura del paisaje.
3. Facilita una análisis de la autocorrelación espacial de diversas variables paisajísticas, como la cobertura del territorio, la humedad del suelo, la geología superficial, a distintas escalas espaciales.
4. Permite calcular índices del patrón espacial de diversas variables paisajísticas de cara a mejorar la planificación espacial del territorio.

El análisis de la estructura espacial que contiene una imagen de satélite ha sido hasta hace unos años un tema mas o menos marginal, tal vez como consecuencia de la escasa resolución espacial que proporcionaban las imágenes. Temas como el reconocimiento automático de ciertas formas sólo se están aplicando desde la disponibilidad de imágenes de muy alta resolución espacial. No obstante, los aspectos de variación espacial en las imágenes se han venido analizando desde los años ochenta, sobre todo orientados a entender mejor las relaciones entre resolución espacial y escala (Woodcock y Strahler, 1987; Woodcock *et al.*, 1988*a*; Woodcock *et al.*, 1988*b*). No obstante, son más numerosos los trabajos que utilizan la variación espacial para mejorar la discriminación de algunas cubiertas, como ya indicamos en nuestro comentario de los clasificadores de contexto (2.3.5). Respecto a los estudios de estructura espacial del territorio, los ejemplos no son muy abundantes. También aquí podríamos hacer una división entre aquellos trabajos que se basan sobre las imágenes medidas en escala continua, ya sean originales, ya aplicando alguna transformación aritmética (índices de vegetación o componentes principales, por ejemplo), y aquellos que se basan sobre imágenes clasificadas, esto es, medidas en escala nominal. Sobre estos dos grupos dividiremos la exposición.

4.2. Técnicas para medir la estructura espacial de una imagen

4.2.1. *Medidas de la variación espacial en imágenes de intervalo*

Hace referencia este término a imágenes en las que los ND están medidos en una escala numérica continua, por lo que pueden aplicarse sobre ellas técnicas estadísticas apropiadas a variables de intervalo. El objetivo de estas técnicas es medir la textura o

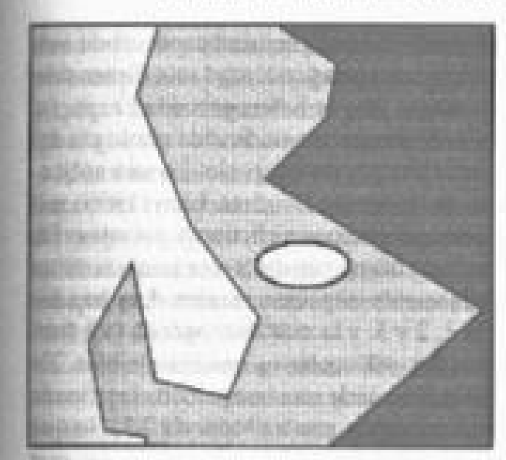
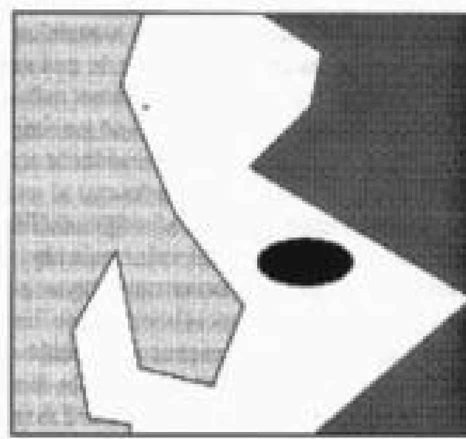



FIG. 7.74. *Ejemplo de dos imágenes con el mismo patrón espacial pero distinto contraste tonal.*

contraste espacial entre los píxeles que componen la imagen. Si en términos de interpretación visual, la textura hace referencia a la diversidad espacial de los tonos de gris en una imagen, los índices numéricos de textura se dirigen a medir ese contraste en la vecindad de los ND de la imagen. Algunos de estos índices operan sobre toda la imagen y proporcionan una sola medida del contraste, mientras otros calculan la textura local, normalmente comparando el ND de un píxel con el de los que le circundan. Los primeros son útiles para comparar la complejidad espacial de distintas zonas, o para analizar la evolución en el tiempo de un determinado sector. En cuanto a los segundos, permiten generar imágenes de textura espacial, sirviendo también como variable auxiliar para la clasificación de categorías temáticas.

Entre los índices aplicables al conjunto de la imagen podemos comentar los siguientes:

1. *Desviación típica (DT) a lo largo de perfiles.* La DT del conjunto de la imagen no resulta apropiada para medir el contraste espacial de la imagen, ya que no mide realmente el contraste espacial sino más bien el tonal (anchura del histograma). Dos imágenes pueden tener el mismo patrón espacial pero DT muy distintas, por contar con una cubierta que presente un marcado contraste espectral con el resto (fig. 7.74). Por esta razón, es preferible emplear la DT calculada para los ND de los píxeles que atraviesen uno o varios transectos de la imagen. En este caso, con algunas de las limitaciones antes apuntadas, la DT resulta más apropiada para ver el contraste espacial, pues informa sobre la variedad entre píxeles que están próximos. Imágenes que hayan perdido diversidad espacial, como consecuencia de cambios en la cobertura del suelo, tenderán a presentar un perfil más plano, con menor aparición de crestas y valles marcados (fig. 7.75).

2. *Dimensión fractal.* La geometría fractal asume que la dimensión de un objeto no es entera, sino real. En la geometría clásica, una línea posee una dimensión de 1, una superficie de 2 y un volumen de 3. En términos fractales, una línea posee una dimensión comprendida entre 1 y 2, con valores tanto más altos cuanto más complejo sea su trazado. En el contexto del análisis de imágenes, la dimensión fractal

puede facilitar una valoración numérica del grado de complejidad espacial de una determinada escena. Al tratarse de una superficie, una imagen tendrá una dimensión fractal entre 2 y 3, aproximándose más a 3 cuanto mayor heterogeneidad espacial presente. Aunque esta medida se ha empleado en diversos estudios de ecología del paisaje, su cálculo no es muy evidente sobre una imagen de intervalo. En una aplicación pionera de la geometría fractal al análisis de imágenes Landsat, Lam (1990) midió la dimensión fractal de imágenes TM correspondientes a distintos paisajes. De acuerdo a lo esperable, el valor más alto calculado correspondió a una imagen de un área urbana, frente a otras con mayor predominio de espacios rurales. Las bandas más heterogéneas espacialmente resultaron la 1, 2 y 3, y la más homogénea la 6 (térmica), por contar con menor resolución espacial y radiométrica que las visibles. En todos los ejemplos se encontró que la dimensión fractal de una imagen no clasificada es bastante alta, superando el valor 2,6 (salvo la térmica, con un valor de 2,2), lo que indica que las imágenes de satélite son espacialmente mucho más complejas que otras variables geográficas, como los modelos digitales de elevación (Lam, 1990). Estudios recientes han aprovechado estas medidas fractales para caracterizar la variación espacial de las alturas de los árboles, de cara al inventario forestal (Drake y Weishampel, 2000), y a analizar los patrones de regeneración post-incendio a partir de imágenes de NDVI (Ricotta *et al.*, 1998).

3. *Auto-correlación espacial (AE).* Las técnicas de AE pretenden medir la asociación entre variables debida a la distancia (Cliff y Ord, 1973). Resulta lógico pensar que los rasgos de la cubierta terrestre se parecen más entre sí cuanto más cerca están, ya que en el paisaje son poco comunes los cambios bruscos. La medida de esta asociación espacial puede obtenerse a partir del índice (*I*), ideado por Moran (1948), que mide la correlación que existe entre cada píxel y sus vecinos:

$$I = (n/2A) \times ((\Sigma_{i=1,n} < \Sigma_{j=1,n} z_i z_j) / \Sigma_{i=1,n} z_i^2) \qquad [7.61]$$

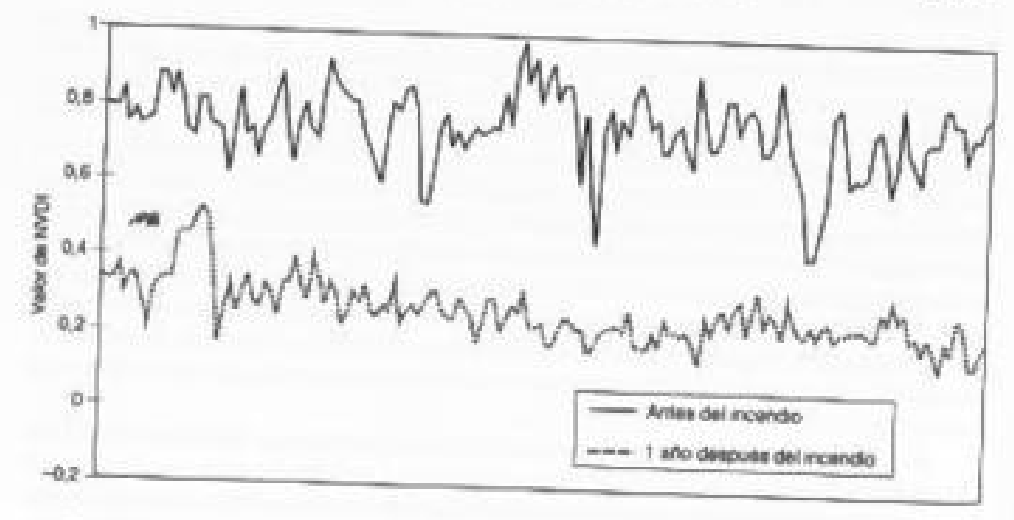


FIG. 7.75. *Cambio en el perfil de los valores de NDVI de una zona como consecuencia de un incendio.* (Chuvieco, 1999*a*.)

donde *n* indica el número de píxeles considerados, *A* el número de posibles uniones entre esos píxeles, z_i la desviación del píxel *i* frente a la media de la imagen ($ND_i - ND_j$), y z_j las desviaciones frente a la media de todos los píxeles adyacentes al píxel *i*. Al igual que el coeficiente de correlación de Pearson, el índice de Moran oscila entre −1 y +1, aumentando cuanto mayor sea la uniformidad espacial del paisaje. Puede calcularse para cualquier dirección (de modo similar al movimiento del rey sobre un tablero de ajedrez), o para algunas direcciones (caso del alfil o de la torre). Este índice se ha utilizado como medida de la uniformidad del paisaje, así como para estudiar los efectos que provocan distintos fenómenos exógenos (Congalton, 1988*a*; Henebry, 1993; Pickup y Foran, 1987).

4. *Semi-variograma.* Basado sobre el mismo concepto de autocorrelación espacial, puede obtenerse un gráfico que muestre cómo se modifica la varianza espacial (esto es, la dispersión de un conjunto de valores vecinos) con la distancia, lo que permite tener una idea bastante precisa de la variación espacial de una imagen. El semi-variograma se obtiene a partir de la siguiente función (Chica, 1988):

$$\gamma(h) = \frac{1}{2NP(h)} \Sigma_{i=1,NP(h)} (ND(x_i + h) - ND(x_i))^2 \qquad [7.62]$$

donde $\gamma(h)$ indica la varianza espacial para una distancia *h*, *NP (h)* el número de píxeles incluidos en ese radio *h*, y ND (x_i) el ND correspondiente al píxel x_i. El semi-variograma se puede calcular en una dirección determinada o, lo que es más habitual en teledetección, en un radio, considerando todas las direcciones. La representación gráfica de $\gamma(h)$ nos muestra cómo aumenta la varianza en función de la distancia (fig. 7.76). Inicialmente la curva tiende a un trazado ascendente, ya que al considerar píxeles cada vez más alejados la varianza aumenta. Sin embargo llega un momento en que se estabiliza, de tal forma que al incrementarse el radio de cálculo no aumenta la varianza significativamente. Esa distancia crítica se denomina alcance (*range*), y el valor al que se estabiliza la varianza, meseta (*sill*). Alcance y meseta son de gran interés para entender la estructura espacial de una imagen. Cuanto mayor contraste espacial presente, tanto el rango como la meseta tenderán a ser mayores. La proporción en la que varía una y otra depende de la disposición del mosaico paisajístico de la imagen.

En un trabajo de gran interés sobre discriminación de morfología forestal se calculó el semi-variograma para varias imágenes obtenidas por videografía (con resolución de 1 m) sobre diversas plantaciones de coníferas. Los autores del estudio observaron que el alcance estaba directamente relacionado con la anchura de la copa —siendo mayor para las parcelas con árboles añejos, muy desarrollados—, mientras la meseta hacía referencia a la estratificación del dosel vegetal (Cohen *et al.*, 1990). Conviene considerar que estas observaciones dependen directamente de la resolución de la imagen y, más en concreto, de la relación entre el tamaño de los objetos que se estudian (en este caso, la anchura de las copas) y el tamaño del píxel. De hecho, estos autores comprobaron cómo las imágenes de vídeo reducían notablemente su capacidad para discriminar rasgos espaciales al degradarse a 10 m la resolución del canal pancromático del SPOT, mientras no permitían deducir una relación significativa entre semi-variogramas y características del dosel forestal al degradarse a la resolución del

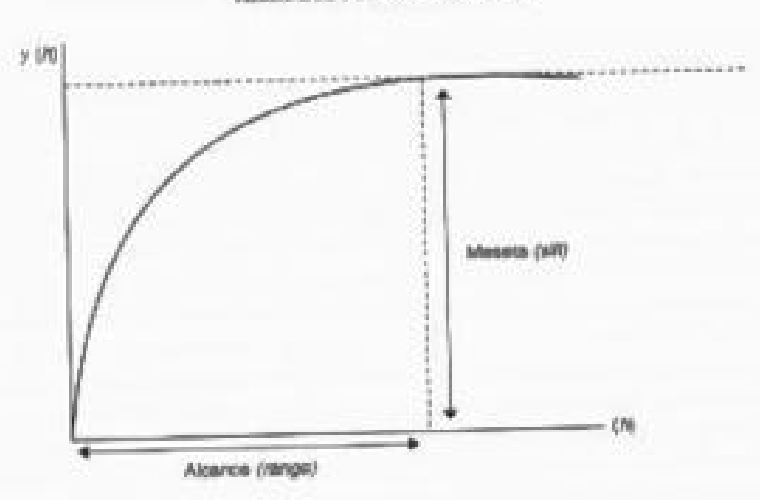


FIG. 7.76. *Representación gráfica de un semi-variograma.*

Landsat-TM (Cohen *et al.*, 1990). En este sentido, el semi-variograma se ha comprobado que resulta de gran interés para describir las relaciones entre el tamaño de los objetos y la resolución espacial del sensor, encontrándose que el máximo de varianza local se produce entre ½ y ¾ del tamaño medio de los objetos (Woodcock y Strahler, 1987). En estudios teóricos y empíricos también se ha observado que la altura del semi-variograma se relaciona con la densidad de la cubierta y el alcance con el tamaño de los objetos (Woodcock *et al.*, 1988*a* y *b*).

En consecuencia, el semi-variograma también ayuda a seleccionar la resolución óptima para abordar un determinado estudio, facilita el diseño de redes de medida *in situ* y de campañas de muestreo, al proporcionarnos una imagen de la distancia máxima a la cual los ND de la imagen se parecen excesivamente entre sí (Caselles, 1987). Se ha aplicado con éxito para analizar la estructura espacial de la vegetación, de cara a diferenciar el impacto territorial de una determinada perturbación (Viedma *et al.*, 1999). Asimismo, como luego veremos (cap. 8), puede aplicarse al estudio de la estructura espacial de los errores, ya sean debidos a la clasificación temática (Congalton, 1988*a*), ya al registro geométrico (Dai y Khorram, 1998).

Además de estos índices que facilitan una evaluación global de la textura de la imagen, también podemos comentar otros métodos que permiten generar imágenes de textura, analizando la heterogeneidad espacial en las inmediaciones de cada píxel. Normalmente, estas técnicas se basan en ventanas móviles, más o menos grandes dependiendo de la distancia de la vecindad que consideremos. A partir de ellas se calcula la textura en torno al píxel central que se evalúe en cada momento, de modo similar a las operaciones de filtraje previamente vistas (cap. 6, apdo. 5.4). Conviene insistir en que estas nuevas bandas de textura pueden utilizarse como entrada en la clasificación digital, facilitando la discriminación de algunas cubiertas que pueden ofrecer valores espectrales similares, pero espaciales muy diferenciados. Este enfoque puede resultar especialmente interesante para discriminar rasgos urbanos, que cuentan con mayor heterogeneidad espacial que cualquier otra cubierta (Molina y Chuvieco, 1996; Smits y Annoni, 1999), pero también se ha mostrado de gran interés en la cartografía de la vegetación, especialmente cuando resulta de interés extraer información sobre sus características estructurales (Riaño *et al.*, 2001*a*; Salas y Chuvieco, 1995; Yool *et al.*, 1985). Entre las técnicas más utilizadas para generar imágenes de textura podemos citar las siguientes:

5. *Desviación típica local.* Se calcula como la dispersión de los ND de una ventana de píxeles en relación con su promedio. Esta medida resulta muy sencilla y se ha comprobado eficaz en el inventario forestal, como indicador de la densidad y homogeneidad de especies, lográndose significativas mejoras frente a clasificaciones sólo espectrales (Strahler, 1984; Strahler *et al.*, 1978). Como puede observarse en la figura 7.77*b*, en una ventana de la imagen Torrel00 próxima al embalse del Vellón, esta medida de textura facilita valores más altos para las zonas más contrastadas espacialmente, pudiendo delimitar con cierta claridad los núcleos urbanos y áreas residenciales de las superficies vegetales.

6. *Diferencias absolutas entre los ND máximos y mínimos de la ventana considerada:*

$$T = |ND_{max,i} - NF_{min,i}| \qquad [7.63]$$

siendo *i* cualquiera de los píxeles adyacentes al central de la ventana. Este sencilla medida se ha empleado para estimar la textura en zonas de praderas afectadas por distin-

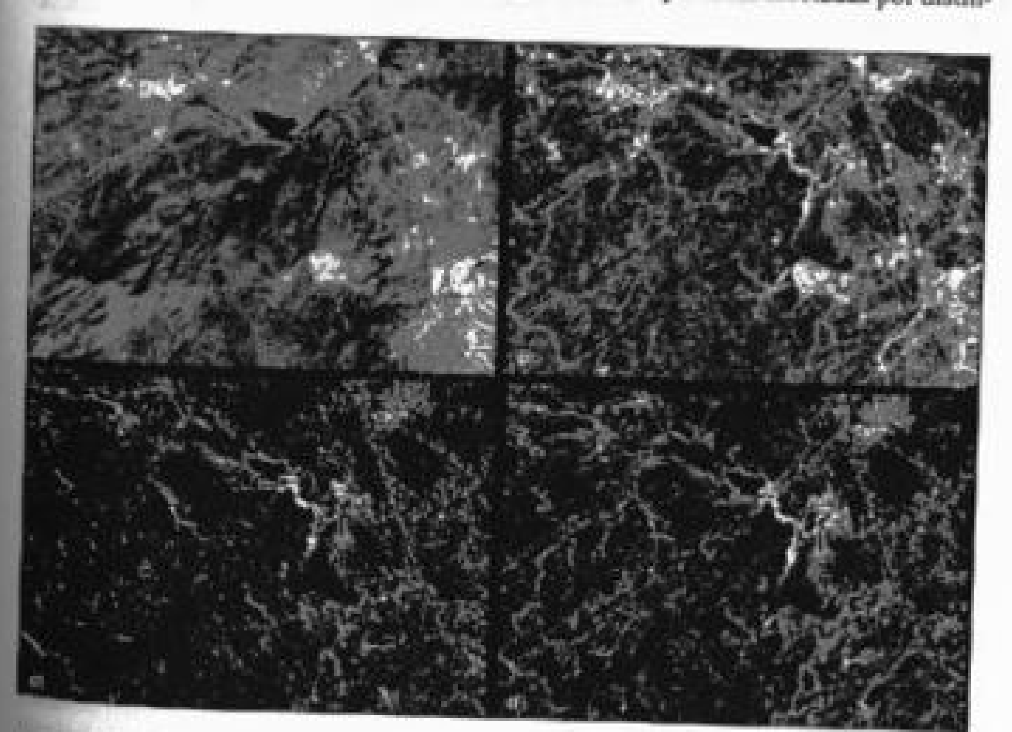


FIG. 7.77. *Diversas medidas de textura sobre la imagen de Torrelaguna: a) Banda 2 original; b) Desviación típica local; c) Contraste sobre la matriz de concurrencia, dirección vertical; d) Idem, dirección promedio.*

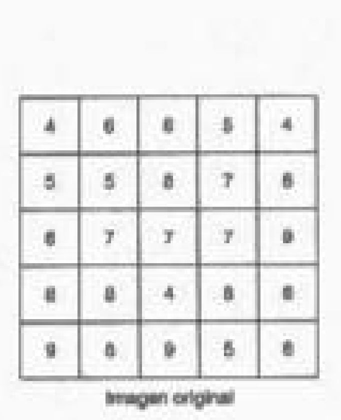
tos procesos ambientales (Briggs y Nellis, 1991). Gracias también a estas medidas de textura ha sido posible discriminar entre frutales de regadío y caducifolias, empleando las bandas TM3 y TM4 (Gordon y Philipson, 1986).

7. *Entropía.* Se define como la relación entre la frecuencia de un determinado ND (F_{ND_i}) y la frecuencia máxima esperable en la ventana de píxeles considerada:

$$\text{Ent} = \sum_{i=0,p} \frac{F_{ND_i}}{n} \ln \frac{F_{ND_i}}{n} \qquad [7.64]$$

donde p el rango de ND en la imagen (256 para una imagen de 8 bits) y n el número de píxeles en la ventana. Esta medida se ha utilizado en la clasificación de áreas urbanas (Gong *et al.*, 1992).

8. *Medidas sobre la matriz de concurrencias.* Se trata de una matriz cuadrada, en la que se incluye la frecuencia relativa ($F_{i,j}/n$) de cada combinación espacial entre un determinado ND_i y otro ND_j (esto es, cuantas veces en la imagen el ND_i es contiguo al ND_j). Para reducir el tamaño de la matriz, y simplificar los cálculos suele reducirse el rango original de la imagen (256 distintos ND), compactándolo en un menor número (habitualmente 16). Pueden calcularse las distintas medidas para una determinada dirección (ángulo entre el píxel central de la ventana y los vecinos) o promediarse las conexiones posibles para 0, 45, 90 y 135° (fig. 7.78). La matriz de concurrencia fue propuesta por Haralick *et al.* (1973), y se ha utilizado ampliamente para valorar las propiedades espaciales en tareas de clasificación. Sobre esa matriz de coincidencias pueden calcularse varias medidas de textura. Algunas de las más utilizadas en teledetección son las siguientes (Gong *et al.*, 1992; Moller-Jensen, 1990; Musick y Grover, 1991; Smits y Annoni, 1999):



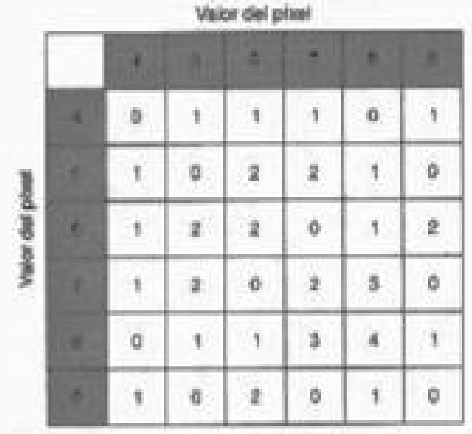


FIG. 7.78. *Ejemplo de una matriz de coincidencias sobre una imagen simulada de 5 × 5 píxeles con 5 ND distintos. Izqda.: imagen original; dcha.: matriz resultante.* (PCI, 1994.)

a) Homogeneidad:

$$H = \frac{\sum_{i=0,n-1} \sum_{j=0,n-1} p_{i,j}}{(1 + (F_i - L_j)^2)} \qquad [7.65]$$

b) Contraste:

$$C = \sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j} (F_i - L_j)^2) \qquad [7.66]$$

c) Disimilaridad:

$$C = \sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j} |F_i - L_j|) \qquad [7.67]$$

d) Media:

$$M = \sum_{i=0,n-1} \sum_{j=0,n-1} (F_i p_{i,j}) \qquad [7.68]$$

e) Desviación típica:

$$DT = \sqrt{\sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j} (F_i - M_i)^2)} \qquad [7.69]$$

f) Segundo Momento Angular:

$$\text{SMA} = \sum_{i=0,n-1} \sum_{j=0,n-1} (p_{i,j})^2 \qquad [7.70]$$

g) Entropía:

$$E = \sum_{i=0,n-1} \sum_{j=0,n-1} (-p_{i,j} \log(p_{i,j})) \qquad [7.71]$$

donde $p_{i,j}$ indica la posición i, j de la matriz de concurrencia (esto es la frecuencia de los cruces entre el ND i y el j), F y C indica la posición en filas y columnas, respectivamente, de esa matriz de concurrencias (en definitiva, cuáles son los ND que se están comparando), M_i señala el valor medio en filas y n el número de columnas y líneas de la matriz (esto es, con cuántos ND distintos se ha realizado el cálculo). En definitiva, p_{ij} mide la probabilidad de que un ND con un valor i sea contiguo a otro con un valor j.

Hemos incluido dos ejemplos del cálculo de textura sobre la imagen Torrel00. Se trata del contraste [7.66], calculado a partir de la banda 2, utilizando la dirección vertical (fig. 7.77*c*) y el promedio de las cuatro direcciones (fig. 7.77*d*). Por comparación con la textura obtenida mediante desviaciones típicas móviles (7.77*b*) se observa que ambas resaltan bastante bien los contrastes espaciales, siendo tal vez más preciso el obtenido a partir de la matriz de concurrencias para subrayar los bordes, mientras la desviación típica destaca el conjunto de la zona heterogénea. La medida direccional resulta de interés para remarcar los contrastes en ciertas líneas de variación de la imagen.

9. *Dimensión textural.* Las medidas de la matriz de coincidencias son de gran interés, pero presentan algunos problemas, como estar influidas por el contraste tonal de la imagen (y no sólo por el espacial), y resultar algo subjetiva la decisión sobre la distancia máxima para considerar dos píxeles como contiguos (Wang y He, 1990). Para solventar estos problemas, otros autores proponen una medida alternativa basada en las desviaciones locales encontradas en una ventana móvil de 3 × 3 píxeles, el central y los ocho circundantes. El valor de la unidad de textura se calcula a partir de la siguiente fórmula:

$$NUT = \Sigma_{i=1,8} 3^{i-1} E_i \qquad [7.72]$$

donde NUT indica número de unidad de textura y E_i es la medida de textura para cada píxel de la ventana. E_i vale 0 cuando el ND de ese píxel es inferior al ND del píxel central de la ventana, 1 cuando es igual y 2 cuando es superior (fig. 7.79). Los NUT pueden ordenarse de varias formas, dependiendo de qué píxel de la ventana inicie el cálculo y en qué sentido se cuente (a favor o en contra de las agujas del reloj). En cualquier caso, el NUT puede variar entre 0 y 6560 (3^8). A partir de ese valor puede calcularse el denominado «espectro de textura»; se trata de un histograma que indica la frecuencia de píxeles de la imagen en cada NUT, y permite observar los rasgos globales de su contraste espacial. A partir de él se han sugerido calcular algunos índices, como el de simetría entre los valores más bajos y más altos del espectro, o el grado de dirección que presentan las texturas (Wang y He, 1990). Se ha comprobado que estas medidas permiten distinguir algunas cubiertas con escaso contraste espectral, como tipos de minerales o de especies forestales. En este segundo caso se observó una notable correlación entre los valores de textura derivados a partir de una imagen pancromática SPOT, y algunos parámetros medidos en terreno como el diámetro de copa, altura del árbol, área basal, edad y diámetro a la altura del pecho (Cohen *et al.*, 1995). También se han empleado para reconocer formas de terreno producidas por deslizamientos de ladera (Hervás y Rosin, 2001).

4.2.2. *Medidas de la variación espacial en imágenes clasificadas*

En este caso partimos de archivos en los que el ND de cada píxel es una etiqueta que identifica la categoría a la que se ha asignado. En consecuencia, aunque se trata de una imagen digital, no pueden aplicarse sobre ella operaciones aritméticas, ya que el ND no indica una relación cuantitativa, sino categórica.

En el campo de ecología del paisaje se han propuesto numerosos índices para medir la estructura espacial de un determinado territorio (Frohn, 1998; O'Neill *et al.*, 1988; Riitters *et al.*, 1995; Saura, 2002). Algunos de ellos se aplican sobre toda la ima-

[illegible]	[illegible]	[illegible]	5	4
[illegible]	[illegible]	[illegible]	7	6
[illegible]	[illegible]	[illegible]	7	9
8	8	4	8	6
9	8	9	5	6

Unidad de textura para el píxel (2,2)

0	2	2
1		2
2	2	2

Valor de E_i

$NUT = 3^0 \times 0 + 3^1 \times 2 + 3^2 \times 2 + 3^3 \times 2 + 3^4 \times 2 + 3^5 \times 2 + 3^6 \times 2 + 3^7 \times 1 = 4.371$

FIG. 7.79. *Ejemplo de cálculo de la unidad textural para la imagen de la fig. 7.78.*

gen, como los señalados para imágenes cuantitativas; otros se calculan para ventanas móviles, normalmente de 3 × 3 píxeles, que se van desplazando sobre la imagen. Entre los primeros cabe destacar los siguientes:

1. *Densidad de manchas, calculada como el número de teselas por unidad de superficie.* Como antes indicamos una mancha o tesela *(patch)* se define por un conjunto de píxeles contiguos con la misma categoría. Mediante técnicas de agregación espacial *(clumping)*, puede convertirse una imagen clasificada en una imagen de teselas, etiquetando con el mismo número aquellos píxeles que pertenezcan a la misma categoría temática y sean contiguos. En definitiva, se trata de generar una nueva imagen en donde se identifiquen las manchas de la misma categoría, o dicho de otra forma, se obtenga una numeración del mosaico espacial presente en la escena (fig. 7.80). Esta técnica es bastante común en el entorno de los SIG, en donde se aplica a mapas temáticos con pocas categorías, pero resulta menos frecuente en el ADI. Habitualmente se calcula para imágenes clasificadas, pero también podría hacerse sobre alguna imagen continua, por ejemplo índices de vegetación o temperatura, previamente segmentada en un número determinado de intervalos (Chuvieco, 1999*a*). El cociente entre el número de manchas y la superficie de la imagen nos ofrece una primera valoración sobre la complejidad paisajística de la zona (Dillworth *et al.*, 1994; Ricotta y Retzlaff, 2000). Un área con una densidad alta de manchas indicará un espacio muy fragmentado.

2. *Tamaño.* Además del número, también parece interesante considerar el área media de las manchas, lo que puede fácilmente calcularse a partir de un simple histograma de la imagen de manchas (número de píxeles en cada parcela). Cuanto mayor sea el área media, en principio contaríamos con un espacio más homogéneo.

1	1	1	3	3	3
1	1	2	4	3	3
2	1	2	4	3	3
2	1	2	4	2	1
2	1	2	2	2	1
4	4	2	2	2	1
4	4	4	2	1	1

1	1	1	2	2	2
1	1	3	4	2	2
5	1	3	4	2	2
5	1	3	4	3	7
5	1	3	3	3	7
6	6	3	3	3	7
6	6	6	3	7	7

FIG. 7.80. *Una imagen clasificada (parte superior) puede convertirse en una imagen de manchas (inferior) aplicando técnicas de agregación espacial.*

3. *Forma: compacidad.* Se ha puesto de manifiesto por varios autores el interés de analizar la forma de las manchas presentes en la zona, ya que con la misma superficie un polígono más alargado presenta mayores opciones a la transmisión de especies y menores obstáculos a la influencia mutua entre las manchas que divide. Los índices de forma más habituales tratan de medir la compacidad de los polígonos, como una relación entre su área y perímetro. Éste es el caso del índice *F* (Gulinck *et al.*, 1991):

$$F = \frac{4\pi A 100}{P^2} \qquad [7.73]$$

donde *A* indica el área y *P* el perímetro.

Otros índices de compacidad se basan en la relación entre la forma de una mancha determinada y la de una figura geométrica estándar. Así se define el denominado cociente *C*, que relaciona la relación área-perímetro de un polígono con los de un círculo, la figura geométrica más compacta:

$$C = \sqrt{\frac{Ap}{Ac}} \qquad [7.74]$$

donde *Ap* indica el área del polígono y *Ac* el correspondiente a un círculo que tuviera el mismo perímetro de ese polígono. Al aumentar *C* el polígono sería más compacto, menos alargado. Para calcular valores promedio de forma para una determinada zona, algunos autores han propuesto ponderar esos índices de compacidad por el tamaño medio de las teselas, de tal forma que el valor resultante sea menos sensible al cambio de escala o de resolución (Saura y Martínez Millán, 2001).

4. *Forma: dimensión fractal.* Como ya hemos indicado, esta medida intenta cuantificar la complejidad de las formas de líneas, superficies o volúmenes. En caso de tratarse de imágenes clasificadas, su cálculo es más sencillo que con las originales, pues se basa en la relación entre el perímetro y el área de los polígonos que forman el mosaico paisajístico. Una forma sencilla de calcular la dimensión fractal (*D*), de cada polígono, es la siguiente expresión (Ripple *et al.*, 1991):

$$P \approx A^{D/2} \qquad [7.75]$$

donde *A* indica el área y *P* el perímetro. El valor medio del conjunto de la imagen se obtendría simplemente promediando *D* para todos los polígonos que la formen. Otros autores proponen calcular la dimensión para el conjunto de un mapa o imagen clasificada, con objeto de comparar la complejidad geométrica de las manchas que forman el mosaico paisajístico (O'Neill *et al.*, 1988). Bajo esta óptica, la dimensión fractal (*D*) utilizando una regresión los logaritmos del área (*A*) y el perímetro (*P*) de los polígonos presentes en el mapa:

$$\log P = a + D/2 \log A \qquad [7.76]$$

la constante de la ecuación (*a*) se denomina, en ocasiones, constante de proporcionalidad.

Algunos autores han observado que la dimensión fractal está directamente asociada con la complejidad paisajística. En un amplio sector del este de EE. UU. se comprobó que *D* ofrecía una valoración numérica de los distintos patrones de uso del suelo; cuando *D* era pequeño, indicaba que las formas resultaban bastante geométricas, lo que apuntaba a una utilización humana del territorio, frente a otros sectores con mayor presencia de espacios naturales, en donde *D* ofrecía un valor mucho más alto (O'Neill *et al.*, 1988; Ricotta *et al.*, 1998). Asimismo, se ha comprobado que la dimensión fractal aumenta al disminuirse la resolución espacial del sensor, especialmente si la imagen presenta escasa heterogeneidad inicial (Benson y MacKenzie, 1995).

5. *Forma: cuadratura.* Algunos autores han comprobado que la constante de proporcionalidad (*a* en la fórmula [7.76]) varía a distintas escalas (Frohn, 1998). Por esta razón se ha propuesto una alternativa que se denomina «cuadratura» (*SqP: Squared-pixel*), calculándose como:

$$SqP = 1 - (4A^{1/2} / P) \qquad [7.77]$$

Este índice varía de 0, cuando el polígono es un cuadrado, a 1 cuando la forma es muy compleja. De acuerdo a Frohn (1998), este índice es más constante a distintas escalas y resoluciones espaciales que la dimensión fractal.

6. *Dispersión.* Hace referencia a la fragmentación de la imagen, y se calcula como la distancia promedio entre los centroides de las distintas manchas (fig. 7.81). La fragmentación del paisaje es un aspecto de gran importancia en la resistencia al movimiento de especies (Ripple *et al.*, 1991).

Hasta aquí las medidas aplicables al conjunto de las manchas que forman el mosaico de cobertura. Junto a ellas se pueden calcular otros índices para ventanas locales (normalmente de 3 × 3 píxeles) que se van desplazando consecutivamente en la imagen, midiendo la variabilidad local en las categorías, de forma similar a como vimos con las imágenes de intervalo. En este ámbito, los índices más conocidos son los siguientes:

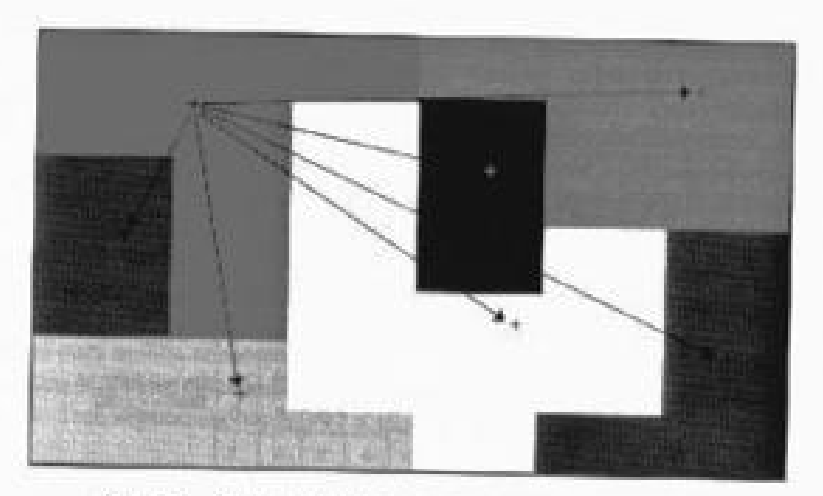


FIG. 7.81. *Cálculo de la dispersión promedio entre manchas.*

7. *Diversidad.* Indica la variedad de categorías que pueden encontrarse en una ventana de la imagen (Turner, 1989):

$$D = -\Sigma_{k=1,m} p_k \ln(p_k) \qquad [7.78]$$

donde p_k corresponde a la proporción de la categoría k en la ventana considerada y m al número de categorías presentes en esa ventana. Cuanto mayor sea la diversidad media, mayor variedad espacial estará presente en la distribución de las cubiertas, o, dicho de otra forma, la zona ofrecerá un mosaico más variado (fig. 7.82). La diversidad está directamente relacionada con la escala de las imágenes, siendo menor al bajar la resolución (Turner *et al.*, 1994).

8. *Dominancia.* Representa la desviación del valor calculado respecto a la máxima diversidad (O'Neill *et al.*, 1988):

$$Do = \ln(m) + \Sigma_{k=1,m} p_k \ln(p_k) \qquad [7.79]$$

con la misma significación de la fórmula anterior. Cuanto más alto es el valor del índice, mayor predominio tiene una categoría sobre las otras en esa ventana.

9. *Fragmentación.* Estos índices intentan medir el grado de ruptura espacial que ofrece el territorio. Uno de los más utilizados, con esta finalidad, es el índice de Contagio (*Con*), que mide la adyacencia entre categorías frente al máximo posible (Li y Reynolds, 1993; O'Neill *et al.*, 1988):

$$Con = 2\ln(m) + \Sigma_{i=1,m} \Sigma_{k=1,m} p_{ik} \ln(p_{ik}) \qquad [7.80]$$

donde p_{ik} indica la proporción de píxeles en esa ventana en donde la categoría i es limítrofe a la categoría k, y m es el número de clases. Frohn (1998 propone dividir toda esta fórmula por $2\ln(m)$, lo que permite escalar el resultado entre 0 y 1. Cuando más próximo a 1 indicará una mayor agregación, mientras valores cercanos a 0 supondrán manchas más pequeñas y dispersas.

El mismo autor propone un indicador más sencillo de fragmentación, que denomina mancha por unidad (*Patch per Unit*, PPU), definido como:

$$PPU = q/(n \cdot TP) \qquad [7.81]$$

1	1	1	1
0	0	0	0
1	1	1	1
0	0	0	0

Div = 0,8365
Dom = 0,0866

1	1	0	0
1	1	0	0
0	0	1	1
0	0	1	1

Div = 0,4900
Dom = 0,0299

1	1	0	0
1	1	0	0
1	1	0	0
1	1	0	0

Div = 0.3183
Dom = 0.0283

1	0	1	0
0	1	0	1
1	0	1	0
0	1	0	1

Div = 0,6870
Dom = 0.0062

FIG. 7.82. *Valores de diversidad y dominancia para imágenes simuladas.*

donde q indicaría el número de manchas, n el número de píxels y TP el tamaño del píxel. Para este autor, esa medida es más resistente que la compacidad a las variaciones debidas a cambios en la resolución espacial, número de clases, y tamaño de la imagen, mostrando su eficacia en área afectada por procesos de deforestación (Frohn, 1998).

10. *Matriz de comparación binaria (MCB).* También se dirige a medir la contigüidad de las categorías presentes en una ventana. Se define como (Murphy, 1985):

$$MCB = \frac{m^2 - \sum_{i=1,m} f_i^2}{2} \qquad [7.82]$$

donde f_i indica la frecuencia de aparición de la categoría i y m el número de categorías. El índice MCB aumenta cuanto mayor es la complejidad espacial, pues considera tanto el número de categorías como su frecuencia. Sin embargo, no tiene en cuenta si las categorías son contiguas o no, por lo que el autor propone complementarlo con algún indicador del número de cambios de categoría que se producen en la ventana considerada.

4.2.3. *Dinámica de la estructura espacial del paisaje*

Las medidas anteriormente revisadas pueden utilizarse tanto para comparar diversos paisajes, como para estudiar la evolución de una zona determinada. En este caso, se trataría de estudiar cómo se transforma la configuración espacial del territorio como resultado de ciertos cambios, debidos a la actividad humana (efecto de ciertas políticas sobre el uso del suelo), o de algún evento esporádico (inundaciones, erupciones volcánicas o incendios). Con este enfoque multitemporal se han abordado numerosos trabajos en ecología del paisaje (Ne'eman *et al.*, 1999; O'Neill *et al.*, 1988; Reinhardt y Ringleb, 1990; Turner *et al.*, 1994). La explicación de esos cambios se basa en factores de índole socio-económico, o en las propias variables geográficas (suelo, topografía, litología, etc.: Pastor y Broshart, 1990).

Un marco para la aplicación de estas medidas a imágenes de satélite es el seguimiento del efecto del fuego sobre la estructura espacial del paisaje (Chuvieco, 1999*a*), tomando como ejemplo el incendio de Buñol, antes comentado. Para evaluar este efecto paisajístico a distintos niveles de resolución se compararon imágenes Landsat-TM y NOAA-AVHRR, adquiridas casi simultáneamente antes y después del fuego. La figura 20* recoge un sector de estas imágenes sobre la zona afectada por el incendio. Junto al evidente efecto de la resolución espacial se muestra una tendencia común entre ambas imágenes, mostrándose con claridad el patrón del área quemada.

Para homogeneizar las medidas antes comentadas y evitar el efecto subjetivo de una clasificación se aplicaron directamente sobre los índices de vegetación (NDVI), calculados para ambos sensores, a partir de los valores de reflectividad. Sobre las imágenes de los NDVI se calculó la media de unos perfiles y el índice de autocorrelación de Moran. Tras segmentar los NDVI a 12, 10, 8, 5 y 3 intervalos,[10] calculamos sobre

10. Fue necesario segmentar la imagen TM del NDVI porque, con el rango original de categorías (250), el número de manchas que se obtenían excedía la memoria dinámica del programa.

TABLA 7.17. *Variación de la estructura del paisaje a consecuencia del fuego (medidas aplicadas a las imágenes de los NDVI: Chuvieco, 1999)*

	TM-Antes del fuego	*TM-Después del fuego*	*AVHRR-Antes del fuego*	*AVHRR-Después del fuego*
I de Moran	0,871	0,919	0,714	0,90
Desviación típica del perfil	11,66	10,14	2,73	3,77
Media textual	18,05	15,68	7,59	6,56

ellos el número de manchas, su compacidad, la diversidad promedio y la dimensión fractal. Los cálculos se realizaron de la misma forma para las imágenes TM y AVHRR.

Las tablas 7.17 y 7.18 recogen los resultados de esta comparación. Como puede observarse, prácticamente en todas las medidas calculadas, la imagen posterior al fuego presenta una mayor homogeneidad espacial, tanto en las imágenes TM como en las AVHRR. La única excepción es la desviación típica del perfil, que aumenta tras el incendio en la imagen AVHRR. Este dato no tiene una gran relevancia, ya que puede ser originado por ruido, puesto que esa línea sólo tiene 15 píxeles AVHRR, lo que resulta poco significativo.

El índice de Moran indica una mayor homogeneidad para la imagen posterior al fuego. El valor de la autocorrelación espacial aumenta tanto en la TM como en la AVHRR, de forma más brusca en esta última (un 125 % frente a un 105 % de la imagen TM). Por el contrario, disminuye la textura media, obtenida a partir de la matriz de coincidencias antes comentada, lo que también indica una mayor homogeneidad después del fuego. La figura 7.83 incluye el semi-variograma de las imágenes TM anterior y posterior al fuego. Este gráfico se construyó a partir de una muestra aleatoria de 1.000 píxeles, considerando un promedio de todas las direcciones. En el trazado general, se observa cómo la imagen posterior al incendio ofrece una mayor varianza, especialmente para las distancias superiores a 500 metros. Esto indica que hay mayor contraste tonal en la segunda imagen, como consecuencia de la presencia de un gran sector quemado. Podría deducirse, por tanto, que la imagen post-incendio es más heterogénea espacialmente, contradiciendo las conclusiones que proporcionan otro tipo de índices. Sin embargo, esta mayor heterogeneidad no es tan clara para las distancias más cortas, por debajo de 210 m (7 píxeles), en las que la imagen de ju-

TABLA 7.18. *Variación de la estructura del paisaje a consecuencia del fuego (medidas aplicadas a 8 intervalos de NDVI: Chuvieco, 1999)*

	TM-Antes del fuego	*TM-Después del fuego*	*AVHRR-Antes del fuego*	*AVHRR-Después del fuego*
Área media	47,48	84,01	1.060,00	1.986,00
Compacidad media	0,289	0,171	0,57	0,58
Desviación típica de la compacidad	0,458	0,210	0,19	0,15
Diversidad media	0,766	0,491	1,06	0,81
Dimensión fractal	2,250	2,272	2,26	2,29

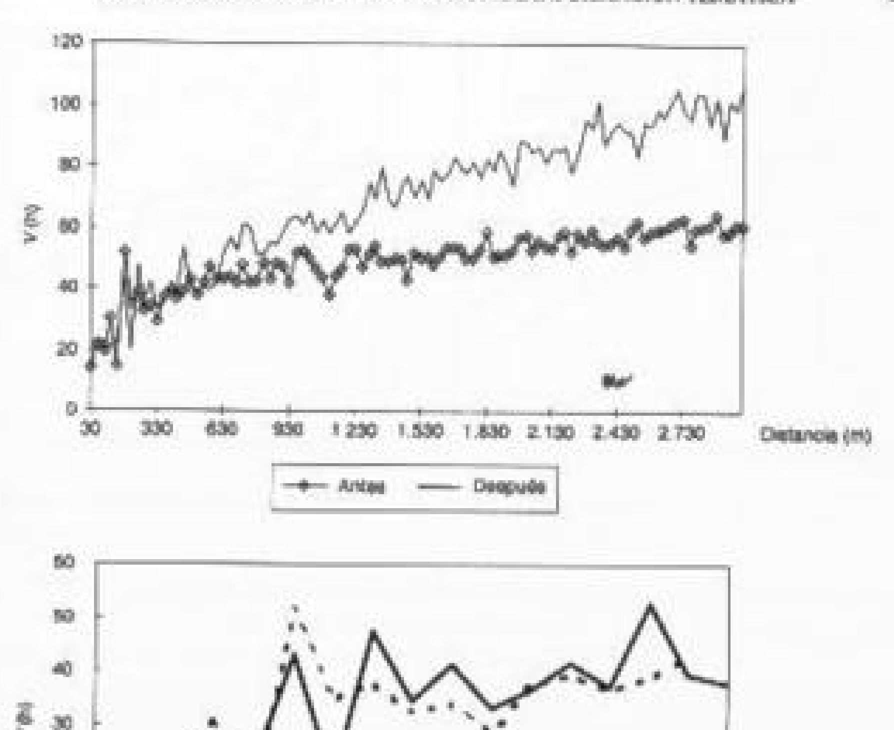


FIG. 7.83. *Semi-variogramas para las imágenes TM anterior y posterior al incendio.*

lio equipara o supera la varianza espacial de la de agosto. Podríamos concluir, en este caso, que la aparición de una mancha quemada incrementa la textura espacial para el conjunto del mosaico, pero no para las relaciones de vecindad, que aparecen como más similares a consecuencia del fuego, confirmando los análisis de los otros índices.

Respecto al número de manchas, en todas las segmentaciones de la escala original del NDVI que hemos realizado se observa una disminución para las imágenes posteriores al fuego (fig. 7.84). Para los datos TM, la caída más brusca entre las dos fechas se registra con una segmentación en 12 niveles de NDVI. En esas imágenes se observa una reducción del 58 % en el número de manchas en la imagen posterior al fuego.

Para la imagen AVHRR, la reducción del número de manchas también es consistente, tanto para los 250 valores originales del NDVI, como para las distintas segmen-

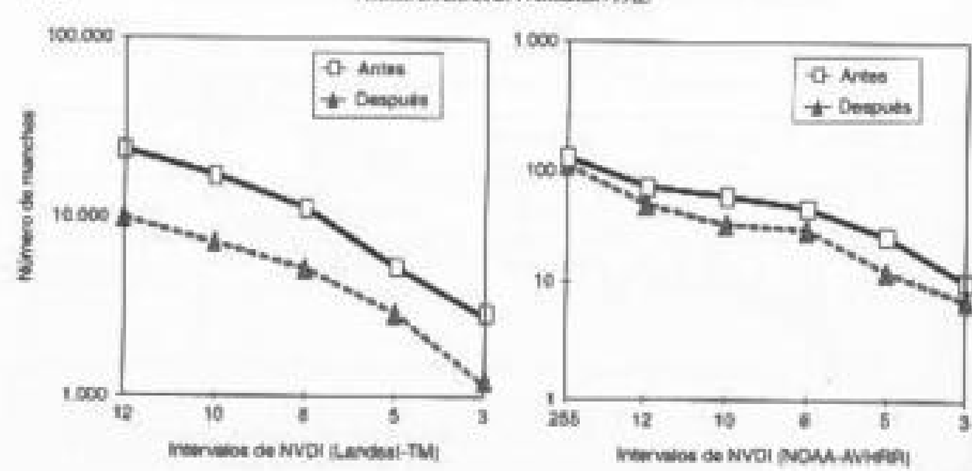


FIG. 7.84. *Disminución del número de manchas tras el incendio.*

taciones (de 12 a 3 grupos). El máximo decremento ocurre con 10 rangos de NDVI, en donde se pierde el 42 % del número de manchas previo al incendio.

Para el caso concreto de segmentar las imágenes en 8 niveles de NDVI calculamos algunas medidas de compacidad y diversidad (tabla 7.18). La superficie media de las manchas, por ejemplo, indica la formación de un mosaico más homogéneo en la imagen TM post-incendio, que casi duplica la superficie media por mancha previa al fuego. En otras palabras, los polígonos de vegetación quemada tienden a ser mayores que los previos, lo que implica que el fuego homogeneiza el territorio, al menos a corto plazo. La imagen AVHRR ofrece la misma tendencia que la TM, con un notable aumento de la superficie media para la imagen posterior al fuego.

En cuanto a la compacidad, para el caso concreto de los 8 rangos de NDVI, se observa una disminución del valor medio a consecuencia del incendio, de modo más claro en la imagen TM que, gracias a su mayor resolución, ofrece mejores posibilidades para el análisis de formas. Las manchas, en consecuencia, tienden a ser más alargadas, probablemente por el efecto del relieve en la dispersión del fuego. La desviación típica de la compacidad también es menor después del fuego, indicando una mayor homogeneidad en la forma de los grupos.

La geometría fractal se incrementa tras el fuego, tanto para la imagen TM como para la AVHRR, indicando que los polígonos son más irregulares a consecuencia del incendio, lo que es coherente con la disminución de la compacidad.

Finalmente, la diversidad media de las manchas es también mucho menor tras el incendio, confirmando una vez más el efecto homogeneizador del fuego. Este efecto se observa tanto en alta como en baja resolución espacial, aunque en ésta resulta menos evidente.

Similares análisis podemos realizar sobre otro tipo de aplicaciones. Por ejemplo, pueden aplicarse medidas de cambio en la forma y tamaño para evaluar la evolución de las dunas en un estudio de desertificación (Collado, 1998: fig. 7.85), o analizar el cambio en la estructura espacial del territorio que producen los fenómenos de deforestación (Frohn, 1998). En este contexto puede resultar de gran interés comparar los pa-

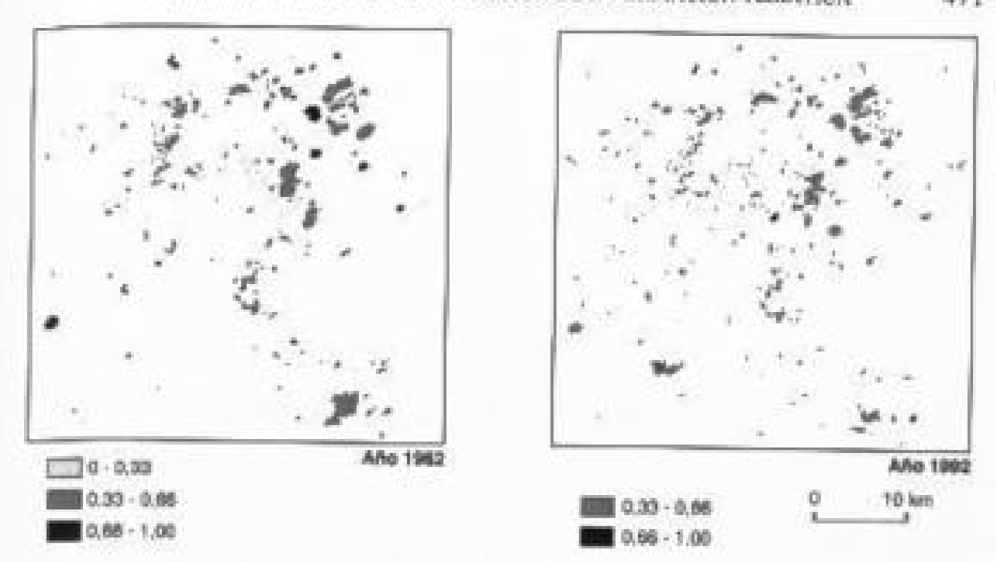


FIG. 7.85. *Cambios en los valores de compacidad de los cuerpos dunares entre 1962 y 1992. Área de San Luis (Argentina): Collado, 1998.*

trones reales, para distintos marcos espaciales, niveles de resolución o grados de abundancia, con simulaciones de estructura espacial del paisaje, realizadas utilizando métodos estocásticos, lo que facilita ver la sensibilidad de las distintas medidas comentadas a los cambios en esos factores de control (Saura, 2002).

CAPÍTULO 8

VERIFICACIÓN DE RESULTADOS

«La vida se nos da,
y la merecemos dándola.»

RABINDRANATH TAGORE, *Gitangali*

1. Necesidad de verificar resultados

Una vez obtenidos los resultados de cualquier tipo de interpretación digital de las imágenes resulta obligado verificar la calidad de los mismos, de cara a comprobar la validez del método y del producto generado. Frecuentemente, la verificación de resultados se considera como el último paso de la clasificación digital, por lo que podría considerarse parte de ella. Ahora bien, estrictamente, debe también incluirse en la interpretación visual de imágenes, así como en otros tipos de análisis digital, como sería la generación de variables continuas (temperatura, clorofila, por ejemplo) o la detección de cambios. Por esta razón, nos ha parecido más conveniente incluir este tema como un capítulo aparte, en lugar de cómo un epígrafe en el dedicado a la clasificación digital.

La verificación de resultados permite al usuario valorar su grado de acuerdo con la realidad, o, dicho de otro modo, el riesgo que asume al tomar decisiones sobre la información que ha generado. Por ejemplo, si el interés del trabajo es ofrecer una estimación del rendimiento de un determinado cultivo, la estimación del error nos permitiría conocer en qué márgenes se mueve el rendimiento real (lógicamente, con un cierto nivel de confianza en las estimaciones), tomando decisiones, por ejemplo, sobre la comercialización futura de ese producto o el tipo de ayudas que requiere su producción.

Este proceso de verificación siempre requiere que comparemos nuestros resultados con una fuente externa, que se considere fiel representante de la realidad presente en el terreno en el momento de adquirir la imagen. Como lógicamente no es posible tener esa información de referencia para todo el área de estudio (si así fuera, no tendría sentido generarla de nuevo mediante teledetección), el proceso de verificación requiere aplicar técnicas de muestreo que nos permitan estimar, con la mayor exactitud y el menor coste posible, el error que contienen nuestros resultados. En consecuencia, este

proceso no es nada más que un ejemplo concreto del muestreo espacial, que se dirige a estimar la variable error a partir de seleccionar una muestra suficientemente representativa de las condiciones del terreno, en el mismo lugar y fecha en que se adquirió la imagen. Posteriormente, el análisis estadístico de esos pares de observaciones (realidad-resultados) nos permitirá estimar numéricamente ese grado de error.

Siendo más sistemáticos en la exposición, podemos indicar que la verificación de resultados incluye las siguientes fases (Congalton y Green, 1999):

— Diseño del muestreo, señalando cuántas parcelas deben muestrearse y cómo se seleccionan.

— Recolectar datos de referencia y resultados sobre esas parcelas seleccionadas en la muestra. Esta fase incluye la selección de las fuentes de la verdad-terreno, el procedimiento para recolectar los datos de referencia, y la extracción de los resultados del análisis digital.

— Comparar los datos de referencia y nuestros resultados, mediante distintos tests estadísticos y la generación de una matriz de confusión.

— Análisis de los errores encontrados, validación de la calidad del proceso y, si es el caso, cuantificación de la fiabilidad de las distintas metodologías aplicadas.

Antes de tratar con más detalle cada una de estas fases vamos a comentar algunos aspectos más generales de la verificación de resultados, exponiendo los procedimientos que se han seguido hasta ahora y las principales fuentes de error que puede presentar el proceso.

2. Medidas de la fiabilidad

La estimación de la exactitud alcanzada por los resultados de una interpretación de imágenes se ha realizado por varios procedimientos. Obviamente, el más sencillo es una valoración cualitativa, que lleva al intérprete a dar por buenos unos productos si ofrecen una visión acorde con su conocimiento de la realidad (podríamos sintetizarlo coloquialmente, con la expresión «parece bueno»). Aunque pueda parecer inaceptable, de hecho todavía sigue siendo éste el procedimiento más universal de valorar los resultados de la interpretación de imágenes en teledetección, ya que esta valoración subjetiva es evidentemente mucho menos costosa y más rápida que una verificación rigurosa. Ahora bien, como es lógico, de este examen pocas consecuencias prácticas y científicas pueden deducirse: ¿puedo estimar el estado hídrico del cultivo con suficiente exactitud para emplear la teledetección operativamente en mejorar el riego?, ¿el método de clasificación que propongo es más preciso para esta aplicación que el utilizado convencionalmente?, son ejemplos de preguntas que no pueden responderse si no se valora numéricamente la precisión de nuestros resultados.

El siguiente método, en orden de dificultad, para valorar los resultados implica compararlos con una fuente estadística convencional, como pueden ser los inventarios agrícolas o forestales que se hacen mediante estimaciones de terreno o encuestas a las cámaras agrarias. Esta opción, que suele denominarse verificación no espacial *(non-site specific)*, nos ofrece, en el mejor de los casos, el grado de ajuste entre las dos

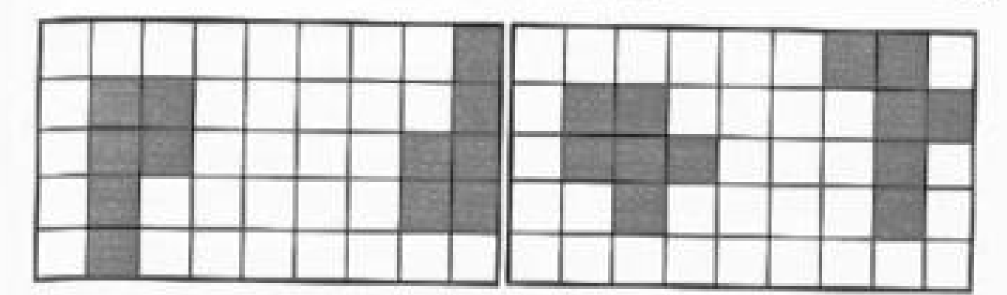


FIG. 8.1. *Problemas que plantea la verificación no espacial. Los totales son los mismos, pero la distribución espacial muy distinta.*

fuentes (teledetección y fuente estadística), pero no informa sobre dónde se presentan los errores. Además, como en cualquier resultado habrá errores por exceso (comisión) y por defecto (omisión), podría obtenerse un saldo ajustado con un notable margen de error (fig. 8.1). En otras palabras, suponiendo al documento de referencia como plenamente fiable, esta medida sólo indica el porcentaje de error, pero no su localización sobre el mapa. Por otro lado, tampoco identifica las confusiones entre categorías que producen ese margen de error, además de que no siempre resulta sencillo ajustar la leyenda de la fuente convencional con la obtenida a partir de imágenes de satélite (GDTA-CEE, 1982).

El tercer método de verificación implica utilizar como datos de comprobación los mismos que se hayan empleado para ajustar el modelo. Esta opción reduce el coste del trabajo de campo, ya que no supone una inversión añadida a la propia realización el modelo, pero incluye un importante sesgo positivo en la valoración de los resultados. Por ejemplo, si usamos las mismas áreas para entrenar y verificar la clasificación, las estimaciones estarán sesgadas, ya que esas áreas sirven para definir estadísticamente a las distintas categorías, y parece lógico que los píxeles incluidos en ellas tengan una mayor probabilidad de clasificación certera que el resto de los píxeles de la imagen. De igual forma, si medimos el error de un ajuste empírico para obtener una variable biofísica (por ejemplo, temperatura), a partir de los mismos puntos que se empleen para generarla, el error de la estimación será más bajo que el encontrado para observaciones independientes, pues precisamente el ajuste se genera minimizando la distancia a esos puntos (fig. 8.2).

Finalmente, la vía más adecuada para verificar es seleccionar una serie de muestras independientes, no utilizadas en la obtención de resultados, que permitan generar una medida estadísticamente más sólida del acuerdo entre imagen y verdad-terreno. Lógicamente, la selección y recolección de esas muestras supone un coste adicional al proyecto, que no repercute en una mejora de su fiabilidad, sino sólo en la medida de ésta. Esta nueva inversión, en tiempo y dinero, explica las reticencias que puede implicar esta fase, aunque no cabe duda que repercute positivamente sobre la solidez del método y los resultados que se ofrecen.

A partir de la obtención de esas muestras independientes puede estimarse el error de los resultados, ya sea mediante algún estadístico continuo (típicamente el error medio cuadrático) en variables de intervalo (clorofila, temperatura, contenido de agua), ya mediante una tabla o matriz de confusión, en donde se resuman los acuerdos y desa-

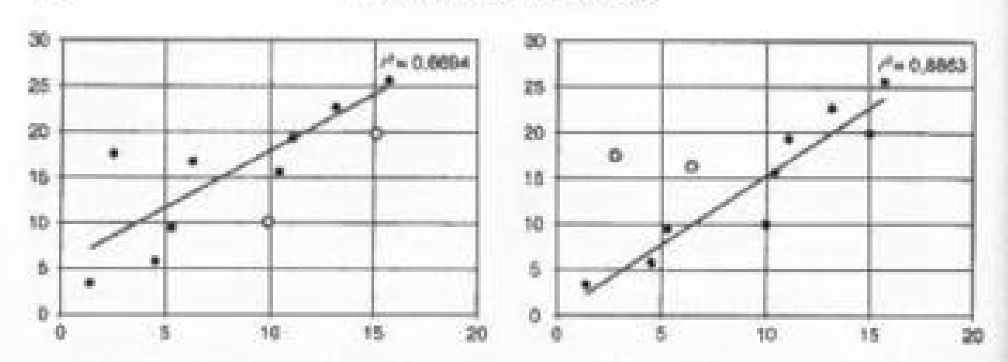


FIG. 8.2. *El empleo de los mismos puntos para calibrar y verificar el modelo implica una estimación sesgada del error. Los círculos blancos indican puntos que se extraen del ajuste, lo que modifica el mismo, aumentando el error en esos puntos.*

cuerdos entre clases del mapa y del terreno. Más tarde comentaremos cómo analizar esta matriz. En ambos casos, puesto que la medida de la fiabilidad se estima a partir de un muestreo, su valor real se mueve entre unos márgenes, tanto más próximos al valor medio cuanto mayor sea al tamaño de la muestra y menor el grado de error. Al tratarse de un muestreo espacial, el resultado nos permite conocer no sólo el grado global de acierto, sino también entre qué categorías se producen las confusiones, facilitando una reflexión sobre la leyenda elegida o el método empleado. Este tipo de verificaciones se califican como «espaciales» *(site specific)*, al ofrecer asimismo una imagen del patrón espacial del error.

Adicionalmente, esta verificación espacial y cuantitativa ofrece la notable ventaja de poder ajustar las estimaciones de superficie a partir de la fiabilidad estimada para la clasificación (Hay, 1988). Los valores de error pueden utilizarse para corregir las estimaciones de superficie asignadas a cada tipo de cobertura. Por ejemplo, si la clasificación nos señala una superficie de trigo correspondiente a 680 ha, y hemos encontrado un error de omisión correspondiente a 0,15, podría estimarse la superficie real cultivada en 782 ha (680 + 0,15 · 680).

3. Fuentes de error en una clasificación temática

La fiabilidad de los resultados depende de distintas variables que conviene tener en cuenta a la hora de valorar los errores estimados en el proceso de verificación. Por un lado, las características del sensor con el que trabajamos, que quizá no ofrezca la resolución necesaria para esa determinada aplicación. Por otro, el método de trabajo, que puede no ser capaz de extraer toda la información contenida en la imagen. Un tercer grupo de factores hace referencia a la propia complejidad del área de estudio. Finalmente, también es preciso considerar los propios errores del proceso de verificación, que lleven a una estimación poco certera del error realmente presente en la imagen.



3.1. Limitaciones del sensor

Dejando a un lado los posibles errores en la adquisición de la imagen debidos a fallos en el funcionamiento del sensor, de la plataforma que lo sustenta, o de los sistemas de recepción y/o grabación de la señal, las limitaciones intrínsecas del sensor pueden suponer una fuente importante de problemas, especialmente cuando se hayan señalado unos objetivos poco realistas para los datos disponibles.

Por ejemplo, puede ocurrir que se intente obtener un determinado nivel de desagregación en la leyenda inapropiado para la aptitud de un determinado sensor, que no cuente con la resolución espacial o espectral para discriminar esas categorías con cierta garantía. Como es bien sabido, el intento de establecer subdivisiones en una clase temática implica un mayor riesgo de error, al pretender discriminar cubiertas que muy probablemente serán similares espectralmente. Por ejemplo, en un estudio sobre el sur de Alemania, se comprobó cómo la combinación de las clases «baja densidad urbana» y «alta densidad urbana» en una clase común «urbana», aumentó la exactitud de la cartografía final en un 83 %, mientras la inclusión de «bosque», en lugar de «bosque caducifolio» y «bosque perennifolio» incrementó la fiabilidad a un 88 % (Schneider, 1980). Similares conclusiones se han extraído por otros autores, en el intento de establecer distintas densidades de edificación en zonas urbanas (Toll, 1984).

En pocas palabras, como se señaló en el cap. 4, es muy importante adecuar la elección del sensor y del método de tratamiento a los requerimientos de escala cartográfica y tipo de categorías que demande un determinado estudio. De otra manera, el riesgo de error se incrementará. Como es obvio, generar mapas de áreas quemadas con imágenes NOAA-AVHRR es más barato y rápido que hacerlo con imágenes Landsat-TM, pero también implica menor fiabilidad, tanto en la detección de áreas como en la delimitación rigurosa de cada una de ellas. Lógicamente, la elección del sensor más conveniente será un compromiso entre la inversión que supone y el nivel de error que puede tolerarse.

3.2. Métodos de análisis

Hemos visto a lo largo de esta obra una amplia variedad de técnicas visuales y digitales para extraer información temática de las imágenes. La elección entre unas u otras dependerá de los recursos disponibles al intérprete y de su propia formación técnica. En cualquier caso, conviene recordar que los errores de una clasificación no son necesariamente inherentes a las características de las imágenes que utilizamos, sino que también pueden deberse a una falta de pericia del intérprete para aplicar el método más apropiado a ese problema.

En ocasiones hemos escuchado que las imágenes Landsat-TM, por ejemplo, no son apropiadas para delimitar áreas urbanas, pues en un determinado estudio se obtenían discriminaciones bastante pobres. Ahora bien, en ese estudio no se habían utilizado más que técnicas relativamente rudimentarias de interpretación (clasificación estadística convencional), sin recurrir a variables texturales o clasificadores de contexto que son más apropiados para el ámbito urbano. Incluso, en ese caso concreto, podría ser más recomendable utilizar directamente la interpretación visual, que permite ex-

traer información más valiosa que un análisis digital sencillo. De la misma forma podríamos juzgar a algún intérprete que obtenga errores elevados en el cálculo de temperaturas de superficie, sin aplicar previamente métodos sólidos para eliminar el efecto atmosférico o las diferencias de emisividad.

En sentido amplio, podríamos incluir entre las deficiencias del método de interpretación los errores derivados de una incorrecta selección de la fecha de adquisición de la imagen. En el caso de las cubiertas vegetales, resulta muy conveniente considerar su dinamismo estacional, de cara a establecer el período más apropiado para abordar su discriminación. Si la imagen se adquiere en una fecha inadecuada es posible que aparezcan errores de asignación, de otro modo solventables. Por ejemplo, en imágenes de verano pueden presentarse problemas para discriminar, digitalmente, núcleos rurales y parcelas cerealistas recién cosechadas (Chuvieco, 1985*a*). El problema se deriva de su comportamiento espectral, muy cercano en esas fechas, puesto que los tejados de estos núcleos suelen fabricarse con el mismo material del suelo agrícola. Evidentemente, esta confusión puede obviarse utilizando imágenes de primavera, cuando estos campos aparecen cultivados, mostrando un comportamiento muy distinto de las zonas edificadas. En otro tipo de cubiertas esta discriminación resulta mucho más problemática, por cuanto sus componentes básicos son muy similares. El ejemplo más típico sería la confusión entre áreas residenciales y bosques caducifolios. Su comportamiento espectral resulta bastante parejo a lo largo del año, ya que la cubierta arbolada (similar en ambas categorías) es la más influyente en la generación de la señal detectada por el sensor. En este sentido se evidencia la necesidad de contar con otros criterios de interpretación, como la textura o el contexto.

3.3. Estructura del territorio

Los errores relacionados con la estructura del territorio incluyen aquellas confusiones derivadas de la disposición espacial con que se presentan las cubiertas objeto de estudio. Aquí pueden incluirse aspectos como la forma, orientación y, sobre todo, tamaño de las parcelas; también el contraste espacial entre cubiertas vecinas, y el grado de mezcla en los distintos tipos de cubierta.

El efecto de la morfología parcelaria resulta especialmente sensible en aquellas regiones que han sufrido una ocupación milenaria del territorio. Esto origina, con bastante frecuencia, solares de muy pequeña extensión, inferior incluso al tamaño del píxel. Como consecuencia, el sensor detecta una señal radiométrica promedio entre dos o más cubiertas, haciendo prácticamente imposible su discriminación (fig. 8.3). El efecto, conocido como error de frontera, es muy habitual en aplicaciones agrícolas, especialmente en los paisajes con parcelamiento muy minucioso.

Estrechamente conectado con este problema se encuentra el efecto de la disposición espacial de los tipos de cubierta. Si existe un claro contraste espectral entre cubiertas vecinas, éstas serán más fácilmente separables que si ofrecen un comportamiento similar, ya que el sensor, al cambiar de una a otra, podrá detectar una señal suficientemente discrepante de tal modo que podamos interpretarla como perteneciente a una cubierta distinta (fig. 8.4). Por ejemplo, un núcleo rural rodeado de cultivos en regadío resulta más fácilmente discriminable que si se enmarca en un sector cerealista

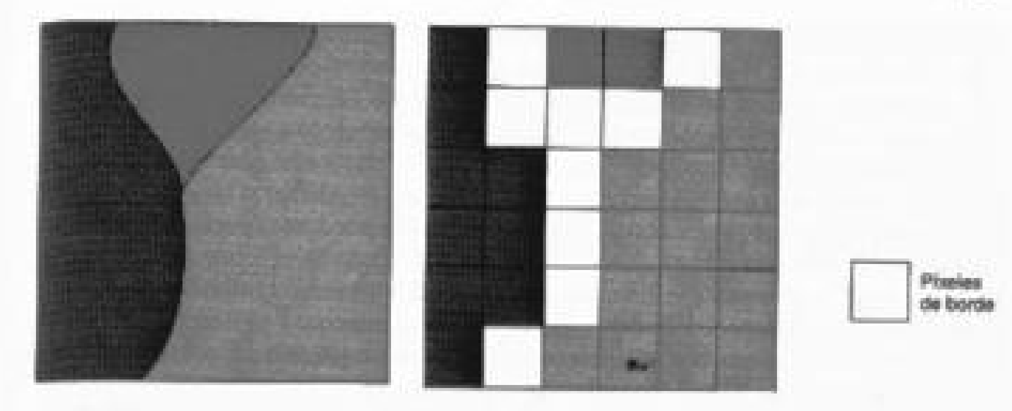


FIG. 8.3. *Consecuencias del error de frontera. Los píxeles de borde registrarán una señal radiométrica intermedia entre dos o más tipos de cobertura.*

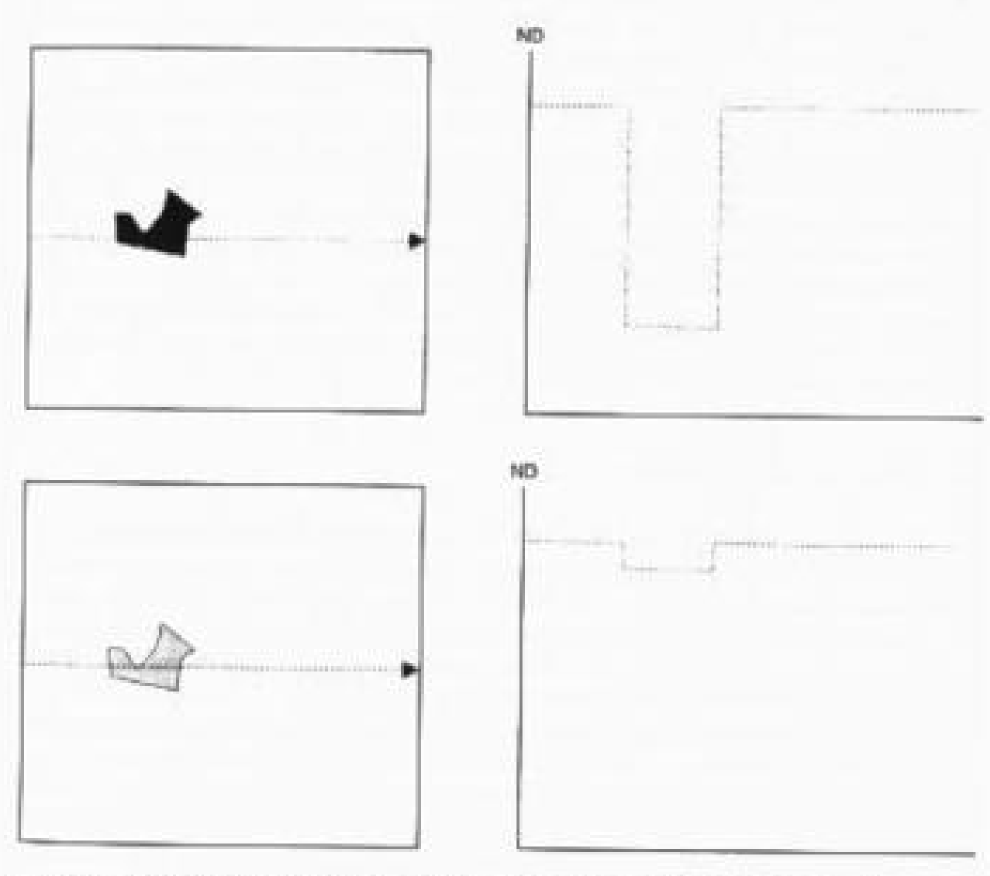


FIG. 8.4. *El efecto del contraste radiométrico entre cubiertas vecinas se observa en los perfiles trazados sobre un área de alto y bajo contraste.*

de secano, ya que esta cubierta cuenta con una respuesta más similar a los núcleos rurales, especialmente cuando se trabaja con imágenes estivales.

En cuanto al grado de mezcla entre cubiertas, puede afirmarse que supone un problema casi insoluble, al menos cuando se aborda el trabajo sólo a partir del valor radiométrico de cada píxel. Otros criterios más abstractos, como estructura, textura o asociación, comunes en análisis visual, pueden paliar ese problema, si bien la distinción de rasgos de tamaño inferior al del píxel sólo se realiza por aproximación. Este efecto es especialmente evidente en cubiertas agrícolas, cuando se produce asociación de cultivos en la misma parcela. En el caso de categorías forestales implica la combinación entre diversas especies de árboles, y de éstas con matorral y pastizales. Las técnicas hiperespectrales que hemos comentado previamente pueden, no obstante, aliviar este problema.

La influencia del tipo de paisaje en los errores de la clasificación se ha puesto en evidencia al estudiar la distribución espacial de los patrones de error. Estos trabajos han demostrado que existe una auto-correlación espacial significativa entre los píxeles mal clasificados (Congalton, 1988*a*). Dicho de otra forma, la aparición de un píxel erróneo está estrechamente relacionada con su ubicación espacial, ya que los errores están notablemente influidos por la estructura del territorio. Esa tendencia a la formación de áreas de error es más clara en aquellas imágenes que muestran menor complejidad espacial; esto es, con patrones de distribución más sistemáticos, como ocurre en el caso de las áreas agrícolas (fig. 8.5). Por su parte, en los paisajes más complejos, como son las áreas urbanas o los espacios de vegetación natural, los errores son menos sistemáticos.

Por último, podemos señalar un grupo de errores de asignación debidos a las condiciones medioambientales de una determinada cubierta. Como ya hemos visto, la distinta orientación, pendiente, densidad y estado fenológico con que aparece una categoría temática implica una variabilidad espectral en torno al comportamiento tipo de esa categoría. Tal dispersión dificulta la caracterización espectral de una clase, provocando solapes y confusiones con categorías vecinas.

3.4. Proceso de verificación

Una última fuente de error en la medida de la fiabilidad puede relacionarse, no tanto con el error en sí de nuestros resultados, sino más bien con el propio proceso de verificación, que no está exento de problemas (Congalton y Green, 1999). Por ejemplo, pueden presentarse problemas de georreferenciación de la imagen o de la parcela de terreno que estemos usando para verificar, que impliquen anotar valores de referencia en un lugar distinto al que estamos realmente verificando.

También pueden producirse problemas cuando la verificación se realiza por varias personas simultáneamente, ya que la definición en el terreno que realizan puede ser inconsistente como fruto de una cierta subjetividad. En este sentido, resulta clave definir con rigor las distintas categorías temáticas, dejando al encuestador el menor margen de interpretabilidad posible. Por ejemplo, hay que establecer taxativamente qué se entiende por una superficie arbolada (especies forestales por encima de una cierta altura promedio), o qué densidad marcará el límite entre las clases pastizal y matorral.

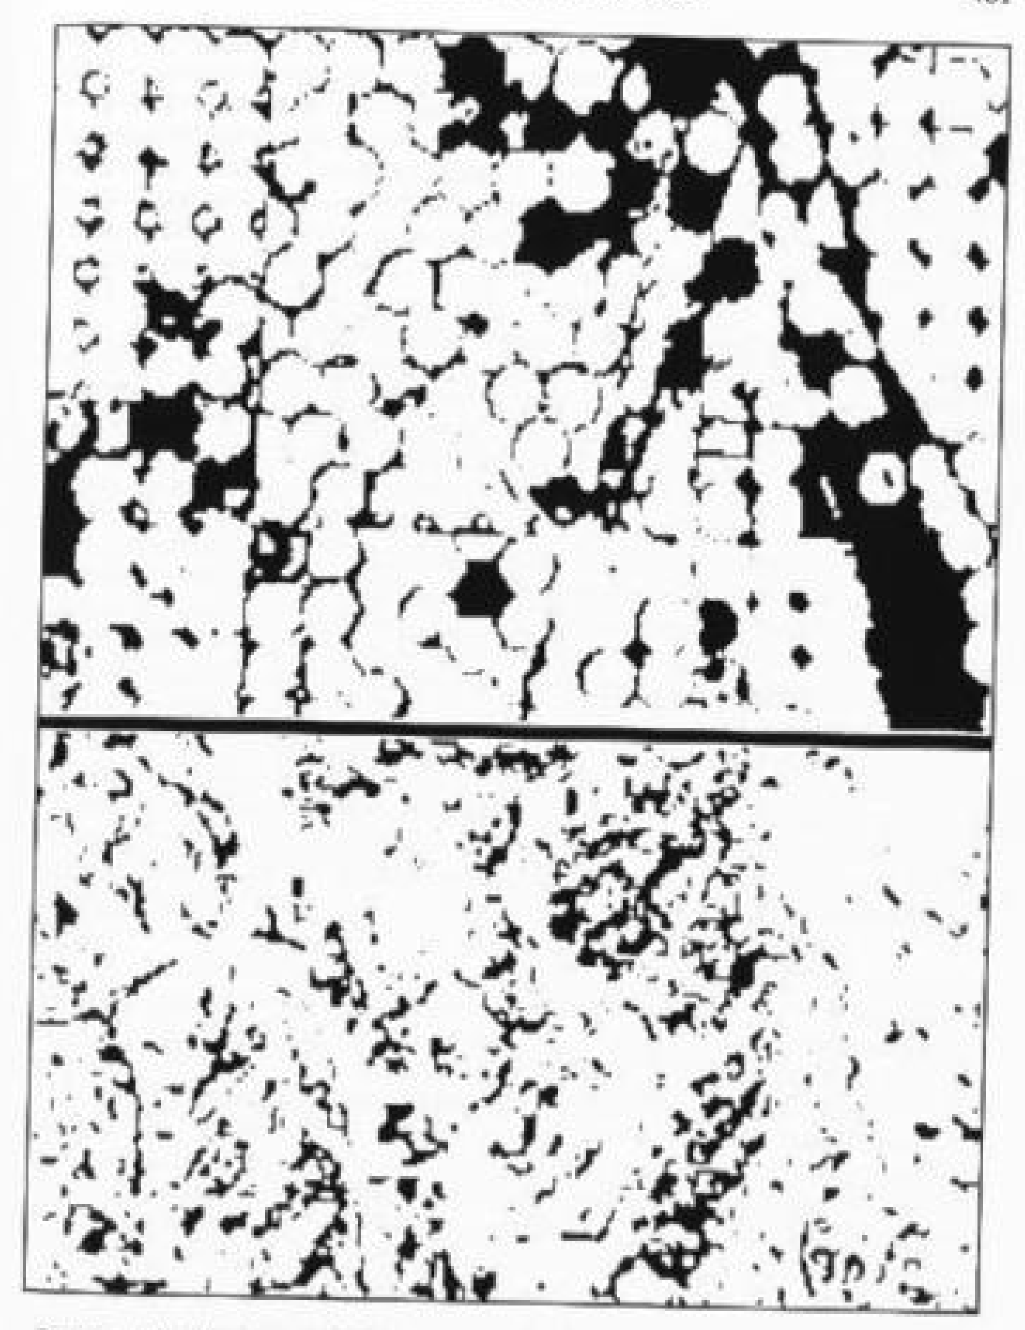


FIG. 8.5. *Distribución espacial del error en las clasificaciones digitales. En la parte superior aparece una imagen correspondiente a una zona agrícola; en la inferior a un área forestal.* (Congalton, 1984.)

Finalmente, el documento de referencia puede también incluir errores. Cuando se utiliza una fotografía aérea como verdad-terreno, la foto-interpretación puede no ser completamente precisa o tratarse de una fecha distinta a la adquisición de la imagen, en cuyo caso estaremos incluyendo como error lo que sería más bien cambio temporal. Este problema también se presenta cuando la inspección en terreno no es coetánea a la adquisición de la imagen. El desfase es especialmente crítico cuando se mide una variable muy dinámica (como sería la temperatura del agua, por ejemplo). Más adelante comentaremos algunos elementos a tener en cuenta para minimizar estos posibles errores.

4. Diseño del muestreo para la verificación

El diseño y desarrollo del muestreo supone la columna vertebral del proceso de verificación. Al igual que en otras aplicaciones, el muestreo espacial sirve en este caso para seleccionar una pequeña parte del área de estudio, de tal forma que sea suficientemente representativa del conjunto. Esa semejanza con la población de referencia debe conseguirse, además, minimizando el tamaño de la muestra, con objeto de reducir los costes del proceso de verificación. En definitiva, la principal virtud de un buen muestreo es seleccionar adecuadamente una pequeña parte del área de estudio para verificar, de tal forma que, siendo lo más pequeña posible, represente adecuadamente el error (o si se prefiere fiabilidad) del conjunto. Esto implica que el esquema de muestreo elegido tiene que permitir realizar estimaciones estadísticas a partir de la muestra, ser sencillo de implementar y analizar, recoger adecuadamente la variabilidad espacial del error y ser de bajo coste. La selección de uno u otro tipo de muestreo dependerá de una serie de factores (Congalton y Green, 1999; Stehman, 1999*b*): ¿cómo se distribuye la información en el área de estudio?, ¿cuál es la unidad de muestreo más apropiada?, ¿cuántas muestras elegir?, ¿cómo elegirlas?

4.1. Distribución de la información

Este aspecto hace referencia al tipo y continuidad espacial de la variable que estamos verificando. En otras palabras, el esquema de muestreo debe considerar si se trata de una variable discreta o continua, y cómo se distribuye esa variable en el espacio, principalmente si presenta rasgos acusados de auto-correlación espacial.

En cuanto al tipo de variables, en verificación de clasificaciones temáticas tendremos que manejar técnicas estadísticas aptas para variables nominales. En consecuencia, el muestreo se basará sobre distribuciones categóricas, siendo la más frecuente la binomial (acierto/error). Por el contrario, cuando se pretenda verificar un mapa de una variable continua, como la temperatura o el contenido de humedad de la vegetación, el muestreo puede basarse en distribuciones continuas, como la distribución normal o la de Poisson.

En cuanto al patrón espacial de la variable, conviene disponer de una estimación de su grado de auto-correlación espacial (Congalton, 1988*a*). Como antes señalamos, la asociación espacial del error tiende a presentar unos patrones diversos si se trata de

superficies naturales o artificiales, principalmente debido al error de frontera. En el caso de paisajes agrícolas, los errores tenderán a asimilarse al patrón parcelario, presentando una estructura regular, mientras serán más aleatorios en el caso de zonas forestales. Este fenómeno puede invalidar la asunción de independencia estadística en la elección de la muestra, clave en cualquier muestreo.

4.2. Unidad de muestreo

La unidad de muestreo hace referencia al elemento sobre el que se extraerá la información de referencia para comparar con nuestros resultados. Con frecuencia se identifica con el píxel, pero no tiene por qué. De hecho, en muchas ocasiones será más conveniente utilizar como unidad de muestreo un grupo de píxeles (por ejemplo, una ventana de 3 × 3), lo que permitirá reducir los posibles errores de la georreferenciación. También puede utilizarse como unidad muestral cada uno de los polígonos temáticos que se hayan definido en la clasificación. En este caso, y puesto que la verificación debe realizarse con los mismos esquemas de la clasificación, no convendrá que la unidad de muestreo sea más pequeña que la mínima unidad cartografiable. De otra manera, se podrían señalar como errores lo que en realidad sería fruto de la generalización.

4.3. Tipos de muestreo

Entre los parámetros arriba enunciados, la elección del método más idóneo de muestreo parece el más controvertido entre los especialistas. Los esquemas más regularmente empleados en el proceso de verificación son (Congalton, 1988*b*; Congalton, 1991; Rosenfeld, 1982; Rosenfeld *et al.*, 1982; Stehman, 1992; Stehman, 1999*b*; fig. 8.6):

1. Aleatorio simple. Los elementos a verificar se eligen de tal forma que todos cuenten con la misma probabilidad de ser seleccionados, y que la elección de uno no influya en la del siguiente. Gracias a este carácter probabilístico, el muestreo aleatorio es bastante sólido estadísticamente, si bien presenta problemas en su aplicación espacial, por cuanto puede suponer elevados costes de desplazamiento. Por otra parte, existe cierta probabilidad de no recoger adecuadamente la variación espacial del error presente en la imagen clasificada, y que algunas categorías, poco frecuentes, no estén representadas en la muestra.
2. Aleatorio estratificado. La muestra se selecciona dividiendo la población en regiones o estratos, de acuerdo a una variable auxiliar (altitud o las mismas categorías temáticas que se han clasificado, por ejemplo). Es más complejo de diseñar que el anterior, pero aporta información sobre sub-conjuntos de la población, además de reducir el error de muestreo siempre que la variable auxiliar esté claramente relacionada con la distribución del error.
3. Sistemático. La muestra se distribuye a intervalos regulares, a partir de un punto de origen señalado aleatoriamente. Garantiza un muestreo completo de la superficie a verificar, pero puede facilitar estimaciones erróneas si existe algún tipo de pa-

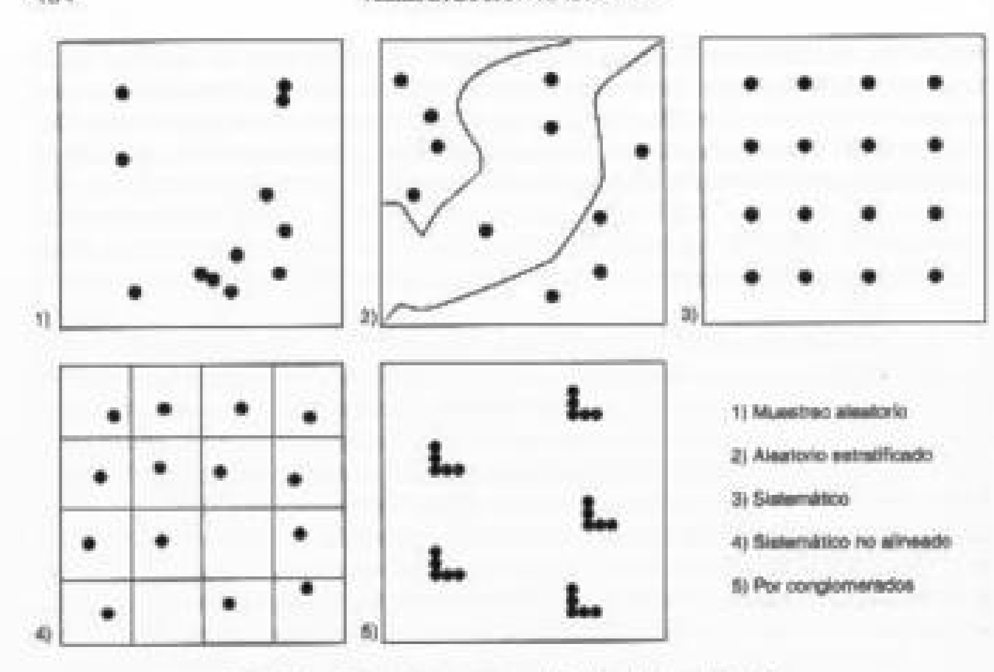


FIG. 8.6. *Tipos de muestreo aplicados a la verificación.*

trón periódico en el área observada (geometría de las parcelas, por ejemplo). Por otro lado, no asegura una estimación probabilística, por cuanto no existe aleatoriedad en la selección de las observaciones.

4. Sistemático no alineado. Modifica el esquema anterior, gracias a variar aleatoriamente —en cada línea y columna del muestreo— una coordenada, manteniendo fija la otra. Esto permite introducir una cierta aleatoriedad en la elección de la muestra, mientras reduce el sesgo debido a la periodicidad. Por otra parte, sigue garantizando una revisión completa del territorio.

5. Por conglomerados. Se selecciona como unidad de muestra un grupo de observaciones, denominado conglomerado *(cluster)*, en lugar de individuos aislados. En otras palabras, en cada punto a verificar se toman varias muestras, en puntos vecinos al elegido aleatoriamente, y de acuerdo a un esquema prefijado. Por ejemplo, un conglomerado podría constituirse por cinco puntos, a cierta distancia del punto central y siguiendo una forma de L. Además, pueden plantearse muestreos en varias fases, cambiando en cada una la unidad de muestreo. Este método reduce los costes de transporte, pero resulta más complejo y, normalmente, menos preciso que los anteriores.

De entre ellos, el muestreo sistemático no alineado ha sido profusamente empleado en tareas de verificación de clasificaciones (Chuvieco, 1986; Dozier y Strahler, 1983; Fitzpatrick-Lins, 1978; Rosenfeld *et al.*, 1982; Stehman, 1992), gracias a las propiedades arriba enunciadas. Otros autores recomiendan métodos alternativos, como el aleatorio simple (Hord y Brooner, 1976), el estratificado por categorías (Ginevan, 1979; Van Genderen, 1978) o el muestreo por conglomerados (Todd *et al.*, 1980). No obstante, pa-



rece conveniente comentar con más detalle el muestreo sistemático no alineado, en razón de su frecuente presencia en trabajos de verificación de clasificaciones.

En este método, la elección de la muestra parte, habitualmente, de dividir el área de estudio en una malla regular de rectángulos, que podrían hacerse coincidir con la cuadrícula UTM. Sobre cada uno de ellos se elige uno o varios puntos de muestreo, de acuerdo a un proceso de selección sistemático, pero no alineado. Esto quiere decir, que, en cada una de las columnas y filas de esa matriz de rectángulos, las coordenadas de cada punto de observación se eligen manteniendo un eje constante, y variando el otro aleatoriamente (fig. 8.7). De esta forma se introduce un cierto rasgo de aleatoriedad, a la vez que se mantiene una observación global del territorio (Berry y Baker, 1968).

Los trabajos experimentales de Congalton (Congalton, 1984; Congalton, 1988*b*) parecen aportar una visión más rigurosa para esta elección. Este autor partió de una serie de tres imágenes clasificadas, de ámbito agrícola, ganadero y forestal, para las que se contaba con una cartografía de referencia suficientemente detallada. Esto permitió superponer digitalmente las clasificaciones obtenidas con los mapas de la verdad-terreno, obteniendo una medida precisa del error total incluido en cada una de las

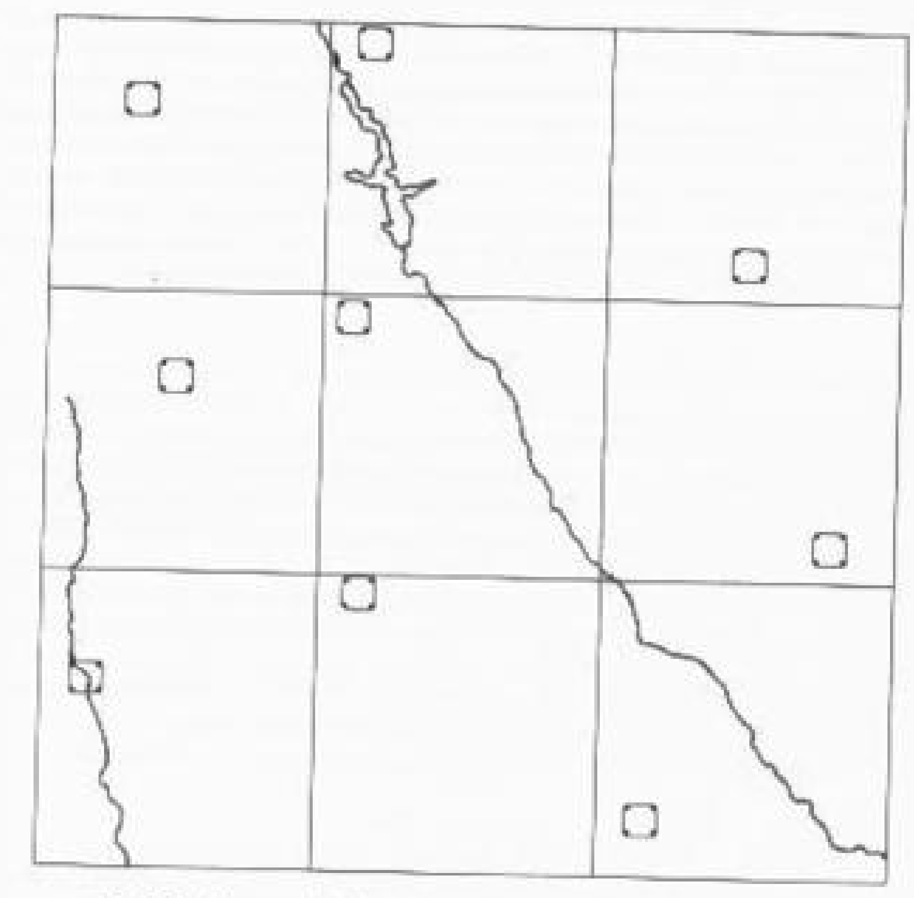


FIG. 8.7. *Diagrama de desarrollo del muestreo sistemático no alineado.*

tres imágenes. A partir de esta medida aplicó los cinco esquemas de muestreo antes aludidos, para estudiar cuál de ellos la estimaba con mayor rigor. Con objeto de investigar la acción de diversos parámetros se seleccionaron distintos tamaños de muestra y se aplicó el muestreo según varios escenarios. Las conclusiones de estos trabajos situaron al muestreo aleatorio simple como el esquema más eficaz, seguido del aleatorio estratificado. El muestreo por conglomerados ofreció también buenos resultados, siendo especialmente apropiado en el caso de verificar grandes superficies en donde los costes de desplazamiento pueden ser cruciales. En ese caso, Congalton recomendaba el empleo de pequeños conglomerados, entre 5 y 25 píxeles de tamaño según la variabilidad de la imagen. El autor desaconseja el empleo del muestreo sistemático y del sistemático no alineado, especialmente cuando la imagen tienda a presentar un error periódico, como es el caso de las zonas agrícolas o cubiertas por pastizales. Por ello sugiere aplicar una evaluación previa de la auto-correlación espacial (Congalton, 1988*a*), que puede facilitar la decisión sobre qué tipo de muestreo resulta más conveniente. En trabajos más recientes sugiere utilizar diversos métodos combinados, extrayendo muestras parciales de cada uno de ellos, a fin de solventar los problemas y aprovechar las ventajas que presentan (Congalton y Green, 1999).

Nada comenta Congalton sobre los costes de desplazamiento asociados a cada uno de estos esquemas de muestreo. Por otras referencias, y nuestra propia experiencia, podemos establecer una jerarquía desde el muestreo aleatorio simple - estratificado - sistemático y por conglomerados, de mayor a menor coste. Asimismo, en la valoración de Congalton no se considera la estimación de la fiabilidad por categorías. En caso de que la clasificación haya incluido cubiertas poco representadas en la zona de estudio, el muestreo aleatorio puede obviarlas, al no implicar un examen sistemático de toda la superficie. Por esta razón, aun con ser de gran interés, los trabajos de Congalton no anulan completamente el empleo del muestreo sistemático no alineado en trabajos de verificación.

4.4. Tamaño de la muestra

Como en cualquier muestreo estadístico, el tamaño de la muestra depende del nivel de probabilidad, o de confianza, que quiera otorgarse a la estimación, del error tolerable en la estimación y de la propia heterogeneidad de la variable. La muestra será tanto más grande cuanto mayor nivel de confianza, menor margen de error y mayor variabilidad incluya el muestreo.

En caso de que quiera verificarse una variable cuantitativa, como contenido de agua en plantas, temperatura o turbidez del agua, el tamaño de la muestra para unos determinados requisitos puede calcularse utilizando la fórmula apropiada al tipo de muestreo que hayamos seleccionado. En términos generales, el parámetro a estimar (en nuestro caso, la diferencia entre la variable estimada de la imagen y la medida en terreno) se encontrará a una cierta distancia del valor estimado en el muestreo:

$$\bar{x} = \hat{x} \pm z \cdot \mathrm{EM} \qquad [8.1]$$

donde $\bar{X}$ sería la media poblacional (el error real presente en la imagen), $\hat{X}$ el valor de error estimado en el muestreo, z el nivel de probabilidad que queramos darle a la estimación y EM, el error del muestreo, que en cada tipo de muestreo se calcula de modo diferente. Este EM depende del tamaño de la muestra y de la varianza de la variable (de la heterogeneidad de la distribución de errores, en nuestro caso). En definitiva, $z \cdot$ EM nos indica el intervalo de confianza (L) en torno al cual se moverá el error realmente presente en la imagen. Para calcular el tamaño de la muestra necesitamos fijar ese margen de confianza, en función de la precisión que queramos darle a los resultados. Eligiendo un valor de probabilidad (z) estándar podremos estimar el tamaño de la muestra para el tipo de muestreo que hayamos seleccionado. Por ejemplo, para el aleatorio simple:

$$L^2 = z^2 \cdot \frac{s^2}{n} \frac{(N - n)}{N} \qquad [8.2]$$

donde L es el intervalo de error tolerable, z la abscisa de la curva normal para un valor determinado de probabilidad, s^2 la varianza muestral, N el tamaño de la población, y n el tamaño de la muestra. Para muestras grandes ($n > 30$) puede prescindirse del último término $((N - n) / N)$ que se conoce como corrección para poblaciones finitas. Para calcular el tamaño de la muestra necesaria para un determinado muestreo necesitamos fijar un margen de error permitido (L), un determinado rango de probabilidad (que fija el valor z) y estimar de alguna manera la varianza muestral (s^2). En definitiva, despejando de la fórmula anterior, el tamaño de la muestra se calcula como:

$$n = \frac{z^2 s^2}{L^2 + \frac{s^2 z^2}{N}} \qquad [8.3]$$

De estos parámetros, el más complicado de cuantificar es la varianza muestral, ya que habitualmente sólo se conoce al terminar el muestreo, por lo que es preciso estimarlo *a priori* de alguna forma. Algunas posibilidades son: estimarla de muestreos previos o a partir del rango de la variable (se ha sugerido un valor de $s = 0{,}29 \times$ rango para una distribución regular y de $s = 0{,}21 \times$ rango para una sesgada).

Por ejemplo, si queremos estimar la exactitud del cálculo de temperatura que hemos realizado sobre una zona de 5.000 km², con un nivel de probabilidad del 95 % ($z = 1{,}96$), y admitimos un error en la estimación de 1,5°, habiendo observado un rango de temperaturas de 20,69° (por tanto, $s = 0{,}29 \cdot 20{,}69 = 6$), podemos sustituir en [8.3]:

$$n = \frac{1{,}96^2 \cdot 6^2}{1{,}5^2 + \frac{6^2 \cdot 1{,}96^2}{5.000}} = 31{,}221$$

lo que quiere decir que tendríamos que medir en 32 puntos de muestreo (asumiendo que la unidad de muestreo es una superficie de 1 km²) para obtener ese margen de precisión.

Para el caso de un imagen clasificada, en donde la variable no es cuantitativa sino categórica, se recomienda emplear la distribución binomial de probabilidad. La expresión más sencilla (sin considerar la corrección para poblaciones finitas) sería:

$$n = \frac{z^2 pq}{L^2} \quad [8.4]$$

donde z sigue siendo la abscisa de la curva normal; p indica el porcentaje estimado de aciertos; q, el de errores ($q = 1 - p$), y L, el nivel permitido de error. El valor de p y q puede estimarse a partir de datos auxiliares o simplemente igualarse a 50.

Por ejemplo, si quiere conocerse el número necesario de puntos de verificación para estimar, con el 95 % de probabilidad, el error de un determinado mapa, suponiendo que los aciertos son del 85 %, y el máximo de error permitido es de ± 5 %, tendríamos:

$$n = \frac{1{,}96^2 \cdot 85 \cdot 15}{5^2} = 195{,}92$$

lo que indica que, al menos, se han de tomar 196 muestras para obtener los niveles de exactitud marcados en el muestreo. Este tamaño puede resultar muy pequeño si hacemos referencia al total de píxeles de la imagen. Hay que tener en cuenta que en esta aplicación no resulta muy apropiado seguir las reglas clásicas de la estadística, ya que el número de píxeles de referencia (el total del área clasificada) es muy grande. En consecuencia, algunos autores proponen un valor mínimo de muestras para obtener una estimación fiable del error. Este umbral se sitúa en 50 píxeles por cada clase temática (Congalton, 1991; Hay, 1979). Se aconseja, además, realizar el muestreo para todas las clases por separado, partiendo de la clase con menor extensión. Ésta marcará la proporción del área a muestrear para el resto de las categorías.

Como ejemplo de trabajo de verificación hemos seleccionado para este capítulo el desarrollado para una cartografía de modelos de combustibles forestales (Salas y Chuvieco, 1995). Ese trabajo se basó en la clasificación digital de una imagen Landsat-TM, adquirida en julio de 1988 sobre el sector oriental de la Sierra de Gredos. En el área de estudio, de unos 500 km², se tomaron 144 parcelas que se visitaron en el terreno para observar los modelos de combustible presentes en la zona. El total de píxeles verificados fue de 9.515, recogiendo el mínimo de 50 píxeles por categoría señalado previamente.

5. Recogida de la información

Una vez diseñado el método y tamaño de la muestra, y localizados los puntos muestrales, el paso siguiente de la verificación consiste en obtener, para cada uno de ellos, el valor de la variable a verificar o la clase temática de referencia y el estimado a partir de la interpretación de la imagen.

El valor de referencia puede obtenerse por medición directa o a partir de fuentes de información auxiliares. La medición u observación directa requiere realizar un trabajo de campo simultáneo a la adquisición de la imagen. Si la variable es muy dinámica (temperatura de superficie, por ejemplo) es especialmente crítica esta sincronía con la imagen, mientras en otros casos (p. ej., tipos de cultivo) puede aceptarse un cierto desfase. Como es lógico, es importante que el instrumento de medición en terreno esté bien calibrado, de tal forma que el valor que consideremos como referencia sea un fiel reflejo de la variación real de la variable. Si medimos clorofila o contenido de agua en vegetación con un instrumento que también incluye un margen de error en la estimación, la verificación de la fiabilidad obtenida por la imagen será un tanto incierta. Como es sabido, algunas de las variables estimables con teledetección pueden obtenerse en terreno a partir de varios procedimientos, pero todos suelen presentar problemas, ya sea por el coste o la lentitud del proceso, ya por la fiabilidad. Por ejemplo, para el caso de la estimación del agua en las plantas existen varias opciones: cámaras de presión osmótica, métodos gravimétricos, empleo de varillas estándar (Slavik, 1974), que pueden facilitar estimaciones diversas para la misma planta. Además, hay que considerar el ruido que implica la diferencia de escala entre la imagen y la medición de terreno, al tratarse de unidades de observación distintas.

Muy frecuente en estos trabajos de verificación es el empleo de radiómetros de campo, aunque también se emplean en la fase de calibración y entrenamiento (Barret y Curtis, 1999*b*). Estos equipos nos permiten medir la misma zona observada por el satélite en condiciones muy controladas y sin influencia de la atmósfera, facilitando además un análisis de la variabilidad espacial de las firmas espectrales (fig. 8.8).



FIG. 8.8. *El empleo de espectro-radiómetros es muy frecuente para verificar y calibrar datos en teledetección.*

Para el caso de verificar mapas de clasificación, el intérprete en terreno tiene que aplicar la misma definición de categorías temáticas que se hizo para clasificar la imagen. Como antes indicamos, esto es especialmente crítico cuando hay varias personas que realizan este chequeo de campo (Congalton y Green, 1999). Una adecuada coordinación entre esas personas puede evitar subjetividades en la asignación de las clases de referencia. Por ejemplo, convendrá definir en términos muy precisos las clases heterogéneas: mosaico de cultivos, pastizal-matorral, vegetación poco densa, etc. Esos términos resultan relativamente vagos y pueden dar lugar a incoherencias en la recogida de la información en terreno. Una forma de reducir este problema es señalar claves dicotómicas para clasificar en el campo, como serían las basadas en porcentajes de cubierta (área forestal se entiende como aquella con una cubierta superior al 75 % arbolado, con alturas superiores a 4 m, por ejemplo).

Otro aspecto a considerar en el trabajo de campo es la correcta localización de las parcelas de control, con objeto de eludir desavenencias más debidas a errores de posición que de asignación, ya que en muchos casos la identificación de ciertos rasgos sobre el terreno no es sencilla en la imagen. El empleo de cartografía de gran escala, y mejor aún de los sistemas de posicionamiento global (GPS), que permiten una georreferenciación bastante precisa sobre el terreno (fig. 8.9), puede facilitar notablemente esta localización.

La alternativa a los trabajos de campo, siempre costosos y lentos, es el empleo de documentos auxiliares de mayor detalle (fotografías aéreas, mapas de cultivos o vegetación), o de sensores automáticos (temperatura, clorofila, aerosoles...). Para el caso de las clasificaciones de la imagen, la fotografía aérea se ha utilizado frecuentemente para validar resultados. La decisión es acertada si ambas fuentes, foto aérea e imagen, son de la misma fecha. De lo contrario, puede plantear problemas de consistencia temporal, importantes cuando las zonas sean muy dinámicas. Por otro lado, la foto-interpretación puede llevar consigo errores, lo que implicaría introducir un ruido en el proceso de verificación. Para el caso de las variables cuantitativas es importante que los sensores estén bien calibrados y faciliten buena resolución temporal, de cara a extraer el dato más cercano al momento de adquisición de la imagen. Esto suele cumplirse en caso de las estaciones meteorológicas automáticas, si bien hay que tener en cuenta que éstas miden las características del aire y no del suelo como hace el sensor remoto (para la temperatura), por lo que las comparaciones no pueden ser directas.

Respecto a qué valor de la imagen extraemos para comparar con el de referencia, puede optarse por seleccionar píxeles aislados, o por grupos de píxeles (típicamente un promedio de una ventana de 3 x 3). Esta segunda opción es la más habitual, ya que reduce el impacto de pequeños errores de georreferenciación que incluya la imagen. En el caso de imágenes clasificadas, la extracción se realizará sobre la unidad de muestreo en terreno, si han sido píxeles individuales o grupos de píxeles se extraerá el valor temático que se les haya asignado, seleccionando la clase puntual o la más frecuente, según los casos. También pueden extraerse los polígonos deducidos de la propia clasificación.

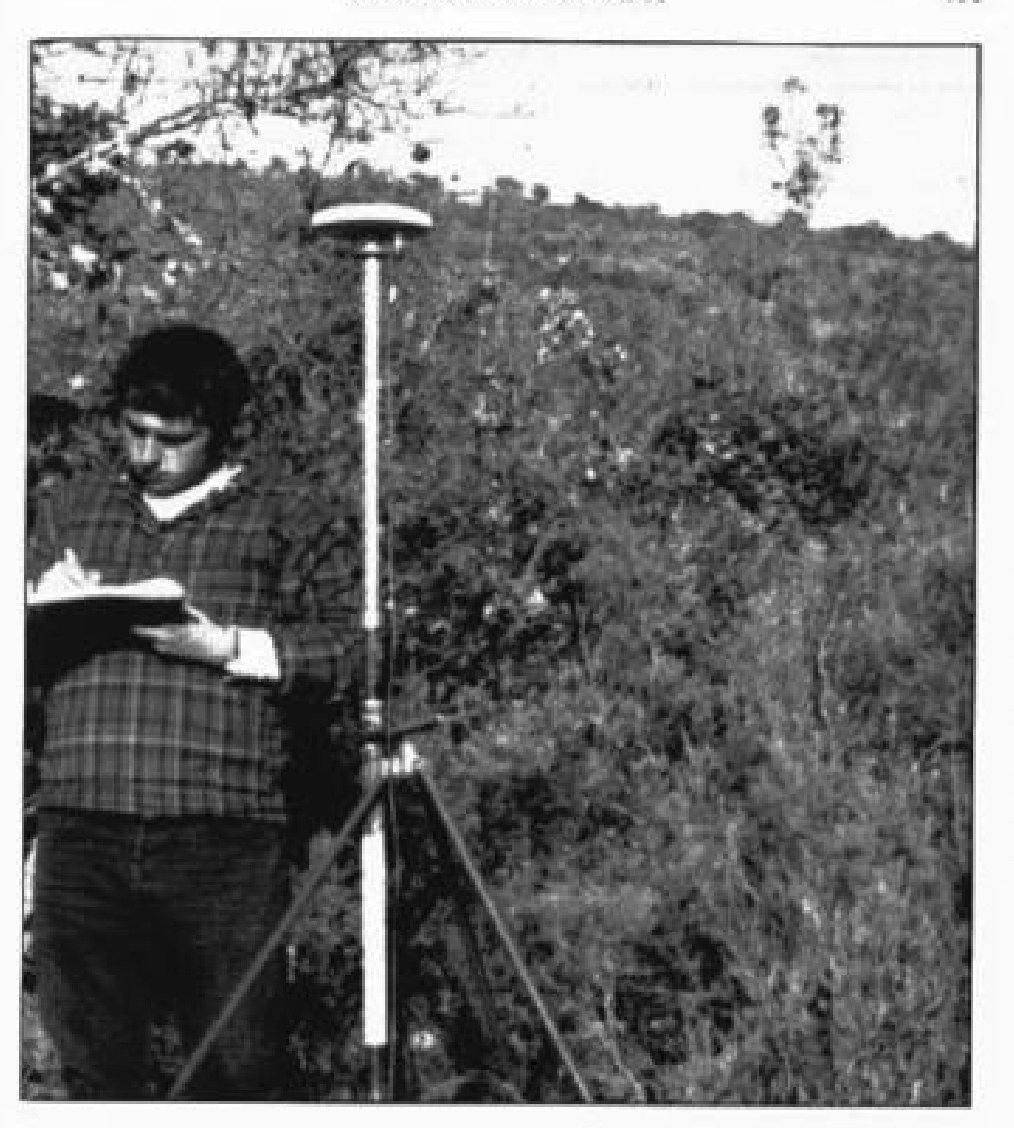


FIG. 8.9. *Localización de parcelas de muestreo con sistemas GPS.*

6. Medidas del error para variables continuas

Una vez obtenidos los datos de referencia puede calcularse el error de la estimación que hayamos realizado a partir de la imagen utilizando cualquier prueba estadística de significación. Lo más habitual es emplear el error medio cuadrático (RMSE), definido ya en el epígrafe de corrección geométrica de imágenes, si bien en este caso se trata de una sola variable (para la corrección teníamos dos, fila y columna). Por tanto, la fórmula [6.66] quedaría como:

$$\mathrm{RMSE} = \sqrt{\frac{\sum_{i=1,n}(\hat{x}_i - x_i)^2}{n}} \qquad [8.5]$$

donde $\hat{x}$ indicaría el valor estimado a partir de la imagen y x_i el medido en terreno. Como antes indicamos, el valor del RMSE será sólo una estimación del error realmente presente en nuestra variable, puesto que se ha obtenido por un muestreo. Deberíamos aplicar los intervalos de confianza vistos en [8.1] para estimar el margen real en el que se mueve el error de la variable deducida de la imagen.

Para una estimación más rigurosa del error del ajuste, la validación debería medirse con puntos no utilizados en la calibración del modelo. De otro modo, el muestreo estaría sesgado positivamente. Puesto que la estimación de una variable de intervalo se realiza frecuentemente a partir de modelos empíricos, como ya vimos en el epígrafe 1 del cap. 7, necesitaríamos una amplia colección de observaciones en campo, unas reservadas para la calibración del modelo, y otras para la verificación. Esta amplia disponibilidad no resulta muy frecuente, ya que las medidas de campo son siempre muy costosas. Si prescindimos de algunas de ellas para reservarlas en la verificación, el ajuste empírico puede quedar comprometido y ser poco significativo. Para obviar este problema, algunos autores han propuesto —en el marco de la georreferenciación de imágenes, pero también puede aplicarse a cualquier variable de intervalo— lo que se denomina validación cruzada, en la que se calcula una variante del RMSE (McGwire, 1996):

$$\mathrm{RMSE}^* = \sqrt{\frac{\sum_{i=1,n}(f(\hat{x}_i) - x_i)^2}{n}} \qquad [8.6]$$

donde $f(\hat{x}_i)$ indicaría la función de ajuste sin utilizar el punto i. Esta medida se calcula para todas las observaciones disponibles, obteniendo finalmente un promedio del error con todas ellas.

7. Medidas del error para imágenes clasificadas

7.1. La matriz de confusión

Para el caso de verificar una imagen clasificada, la recogida de la clase de referencia y la extracción del valor de la imagen permitirá obtener un listado de puntos de verificación, para los que poseemos tanto su cobertura real como la deducida por la clasificación. Con esa lista puede generarse una tabla, denominada «matriz de confusión», puesto que recoge los conflictos que se presentan entre categorías. En esta matriz las columnas suelen indicar las clases de referencia, y las filas las categorías deducidas de la clasificación. Lógicamente, ambas tendrán el mismo número y significado; se trata, en suma, de una matriz cuadrada: $n \times n$, donde n indica el número de categorías (tabla 8.1). La diagonal de esta matriz expresa el número de puntos de verificación en donde se produce acuerdo entre las dos fuentes (mapa y realidad), mientras los marginales suponen errores de asignación. La relación entre el número de puntos correcta-

Tabla 8.1. *Estructura de una matriz de confusión (clasificación)*

	Referencia						
	Clase 1	*Clase 2*	*Clase 3*	*Clase n*	*Total*	*Exactitud usuario*	*Error comisión*
Clase 1	X_{11}				X_{1+}	X_{11}/X_{1+}	$1-X_{11}/X_{1+}$
Clase 2		X_{22}			X_{2+}	X_{22}/X_{2+}	$1-X_{22}/X_{2+}$
Clase 3			X_{33}		X_{3+}	X_{33}/X_{3+}	$1-X_{33}/X_{3+}$
Clase n				X_{nn}	X_{n+}	X_{nn}/X_{n+}	$1-X_{nn}/X_{n+}$
Total	X_{+1}	X_{+2}	X_{+3}	X_{+n}	ΣX_{ij}		
Exactitud productor	X_{11}/X_{+1}	X_{22}/X_{+2}	X_{33}/X_{+3}	X_{nn}/X_{+n}			
Error omisión	$1-X_{11}/X_{+1}$	$1-X_{22}/X_{+2}$	$1-X_{33}/X_{+3}$	$1-X_{nn}/X_{+n}$			

mente asignados y el total expresa la fiabilidad global del mapa. Los residuales en columnas indican tipos de cubierta real que no se incluyeron en el mapa, mientras los residuales en filas implican cubiertas del mapa que no se ajustan a la realidad. En definitiva, representan los errores de omisión y de comisión, respectivamente (Aronoff, 1982; Story y Congalton, 1986).

El interés de estas tablas de confusión proviene de su capacidad para plasmar los conflictos entre categorías. De esta forma, no sólo conocemos la fiabilidad global de la clasificación, sino también la exactitud conseguida para cada una de las clases, así como los principales conflictos entre ellas.

En la tabla 8.2 se incluye un ejemplo de una de estas matrices, lo que permite observar las principales confusiones presentes en esa clasificación. En este ejemplo se trataba de discriminar entre cubiertas vegetales en función de su comportamiento frente al fuego de superficie (Salas y Chuvieco, 1995). Ese objetivo es complicado de

Tabla 8.2. *Matriz de confusión obtenida para una clasificación no supervisada de una imagen TM e información auxiliar*

		Referencia											
		1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*	*Total*	*Exactitud usuario*	*Error comisión*
Clasificación	1	551	4		17	12	48	23	128		783	70,4	29,6
	2	71	543	190		193	24	75	75		1.171	46,4	53,6
	4	57	75	209	3	67	55	145	17		628	33,3	66,7
	5	7	3	2	525	49	2	19	9		616	85,2	14,8
	6	207	31	57		273	3	5			576	47,4	52,6
	7											0,0	100,0
	9		116	751	46	107	393	2.507	9		3.929	63,8	37,2
	A	255	61	31	1	31	57	84	1.145		1.665	68,7	31,3
	B									147	147	100,0	0,0
Total		1.148	833	1.240	592	732	582	2.858	1.383	147	9.515		
Exactitud productor		48,0	65,2	16,9	88,7	37,3	0,0	87,7	82,8	100,0			
Error omisión		52,0	34,8	83,1	11,3	62,7	100,0	12,3	17,2	0,0			

Los números 1 a 9 hacen referencia a los modelos combustibles definidos por el ICONA: 1 pastizal; 2 pastizal arbolado; 4 matorral denso y alto; 5 matorral raso; 6 matorral de altura intermedia; 7 matorral bajo arbolado; 9 cubiertas forestales con sotobosque limpio. La clase A identifica las áreas agrícola-ganaderas y urbanas, y B las láminas de agua.

TABLA 8.3. *Matriz de confusión para la clasificación mixta con las bandas Landsat-TM e información auxiliar (igual significado que la tabla 8.2)*

		Referencia											
		1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*	*Total*	*Exactitud usuario*	*Error comisión*
Clasificación	1	927	49	63		42		5	87		1.173	79,0	21,0
	2	35	575	74		70	6	34	58		852	67,5	32,5
	4	6	7	812		39	104	145			1.113	73,0	27,0
	5				590	19		1			610	96,7	3,3
	6	11	192	77		489	1	6			776	63,0	37,0
	7		2	11			93	51			157	59,2	40,8
	9	99	5	181		59	329	2.273			2.946	77,2	22,8
	A	70	3	22	2	14	49	343	1.238		1.741	71,1	28,9
	B									147	147	100,0	0,0
TOTAL		1.148	833	1.240	592	732	582	2.858	1.383	147	9.515		
Exactitud productor		80,7	69,0	65,5	99,7	66,8	16,0	79,5	89,5	100,0			
Error omisión		19,3	31,0	34,5	0,3	33,2	84,0	20,5	10,5	0,0			

abordar mediante teledetección, ya que algunas clases se ven enmascaradas por un dosel vegetal continuo, además de la propia dificultad para distinguir categorías mixtas (pastizal o matorral arbolado). Las principales confusiones que se observan en las tablas 8.2 y 8.3 son el solapamiento entre los distintos tipos de matorral (modelos de combustible 4, 5 y 6, sólo separables por la altura, lo que resulta complejo de diferenciar sobre imágenes Landsat), la difícil discriminación del matorral arbolado (modelo 7, sólo presente en la clasificación de la tabla 8.3), la confusión entre matorral y pastizales y la mezcla entre arbolado y matorral alto-denso.

Si se realizó correctamente la fase de entrenamiento, la mayor parte de estas confusiones ya habrían sido detectadas, pero aquí se ofrece una medición mucho más explícita de estos problemas. A partir de estos datos puede orientarse la búsqueda de nuevos métodos de clasificación, el empleo de imágenes de otras fechas, o el de bandas auxiliares (modelo digital de elevaciones o suelos), con objeto de facilitar un documento suficientemente certero. Asimismo, puede optarse por una leyenda simplificada, que reduzca las confusiones entre categorías de transición.

7.2. FIABILIDAD GLOBAL

A partir de la matriz de confusión pueden generarse toda una serie de medidas estadísticas que permitan validar numéricamente los resultados de distintas técnicas de clasificación. La medida más simple consiste en calcular la fiabilidad global del mapa, relacionando los elementos de la diagonal con el total de puntos muestreados:

$$\hat{F} = \frac{\sum_{i=1,n} x_{ii}}{\sum_{i=1,n} \sum_{j=1,n} x_{ij}} \qquad [8.7]$$

Para los datos de las tablas 8.2 y 8.3, la fiabilidad estimada sería del 62 y 75 %, respectivamente. Como ya hemos indicado, a partir de este valor estimado en el mues-

treo puede calcularse el intervalo de confianza donde se situará la fiabilidad real alcanzada por la clasificación. Así, de acuerdo a [8.1], tendríamos en este caso:

$$F = \hat{F} \pm z \cdot \text{EM} \qquad [8.8]$$

El error del muestreo para estas validaciones puede generarse a partir de la fórmula del muestreo aleatorio simple:[1]

$$\text{EM} = \sqrt{\frac{pq}{n}} \qquad [8.9]$$

Para la matriz de la tabla 8.2, por ejemplo, el número de píxeles bien asignados fue 5.900, frente a los 9.515 totales de la muestra. Esto significa una fiabilidad estimada del 62 %. Con un nivel de significación de 0,05 (probabilidad del 95 %), el error del muestreo sería:

$$\text{ES} = \sqrt{\frac{62 \times 38}{9\,515}} = 0{,}497$$

y, por tanto, el intervalo de confianza puede calcularse como:

$$F = 62 \pm 1{,}96 \times 0{,}497 = 62 \pm 0{,}975$$

En definitiva, puede asegurarse, con un 95 % de probabilidad, que la fiabilidad real se encuentra entre 61,025 y 62,975 %.

7.3. FIABILIDAD DEL USUARIO Y DEL PRODUCTOR

Conviene tener en cuenta que la fiabilidad global puede ocultar importantes diferencias entre categorías, que escondan niveles de exactitud muy diversos. Por ello, un análisis más riguroso debe también considerar las celdillas marginales de la matriz. En el caso de las columnas, los marginales indican el número de píxeles que, perteneciendo a una determinada categoría, no fueron incluidos en ella. Éstos se denominan errores de omisión (E_o). Para cada clase se calculan como:

$$E_{o,i} = \frac{X_{+i} - X_{ii}}{X_{+i}} \qquad [8.10]$$

donde X_{+i} indica el marginal de la columna i, y X_{ii} la diagonal de dicha columna.

1. No consideramos aquí la corrección sobre poblaciones finitas, pues apenas añade nada al cálculo, ya que la proporción de la muestra sobre la población de píxeles es muy pequeña.

De forma similar, las celdillas no diagonales de las filas expresan los errores de comisión; esto es, píxeles que se incluyeron en una determinada categoría perteneciendo realmente a otra:

$$E_{c,i} = \frac{X_{i+} - X_{ii}}{X_{i+}} \qquad [8.11]$$

donde X_{i+} indica el marginal de la fila i, y X_{ii} la diagonal de dicha fila.

Los errores de omisión y comisión expresan dos enfoques del mismo problema. Los primeros se refieren a una definición imperfecta de la categoría. Los segundos, a una delimitación excesivamente amplia. Desde otro punto de vista, algunos autores hablan de exactitud del usuario y del productor (Aronoff, 1982; Story y Congalton, 1986). La primera está en relación inversa con los errores de comisión, mientras la segunda lo está con los de omisión:

$$F_{p,i} = \frac{X_{ii}}{X_{+i}} \qquad [8.12]$$

y

$$F_{u,i} = \frac{X_{ii}}{X_{i+}} \qquad [8.13]$$

para cada una de las n categorías de la clasificación. El interés de esta distinción puede mostrarse con un sencillo ejemplo. Si para una especie forestal el error de omisión es bajo, existe una alta probabilidad de que la superficie realmente ocupada por esa especie esté incluida en el mapa, lo que significa un logro para el productor del mismo. Sin embargo, puede a la vez haberse producido un alto error de comisión, lo que implica que la probabilidad de que una zona clasificada en el mapa como tal especie lo sea realmente es muy baja. Esto supone un grave riesgo para el usuario de esa información.

Ambos errores (o, si se prefiere, fiabilidades) están bastante relacionados, pero puede ocurrir que uno sea muy bajo cuando el otro es elevado. El caso más extremo se daría cuando el intérprete hubiera identificado como de un determinado cultivo todo el espacio cultivado en una zona, cuando en realidad existiera una amplia diversidad de cultivos. El error de omisión sería nulo (todo el territorio ocupado por ese cultivo estaría recogido en el mapa), pero el de comisión alto (sólo una pequeña parte de lo que el mapa señala como perteneciente a ese cultivo sería realmente tal).

En el caso de la matriz de confusión recogida en la tabla 8.2, el modelo 9 (arbolado denso) ofrece una fiabilidad del productor del 87,7 %; esto es, aproximadamente nueve de cada diez superficies que tienen realmente esa cubierta están incluidas en la clasificación como tal. Sin embargo, la fiabilidad del usuario supera ligeramente el 60 %, lo que quiere decir que sólo tres quintas partes de las zonas clasificadas como esa cubierta realmente lo son. Aquí el error de omisión es bajo, pero el error de comisión es medio-alto. Ambas medidas son complementarias y de gran trascendencia. La primera desde el punto de vista de quien produce una determinada clasificación, la segunda de la persona que la utiliza.

7.4. El estadístico kappa

Hasta ahora hemos estudiado lo que ocurre en la diagonal y en los residuales de filas y columnas. También resulta de gran interés analizar las relaciones múltiples entre las distintas categorías. Con este objetivo se introdujeron en los años ochenta algunas técnicas de análisis categórico, idóneas para el estudio global de matrices de confusión.

Uno de los índices más empleados, en este sentido, es el estadístico kappa (κ), que mide la diferencia entre el acuerdo mapa-realidad observado y el que cabría esperar simplemente por azar. En definitiva, intenta delimitar el grado de ajuste debido sólo a la exactitud de la clasificación, prescindiendo del causado por factores aleatorios. La estimación de κ se obtiene a partir de la siguiente fórmula (Hudson y Ramm, 1987):

$$\hat{\kappa} = \frac{n \sum_{i=1,n} X_{ii} - \sum_{i=1,n} X_{i+} X_{+i}}{n^2 - \sum_{i=1,n} X_{i+} X_{+i}} \qquad [8.14]$$

en donde n sería el tamaño de la muestra, X_{ii} el acuerdo observado, y el producto de los marginales (X_{i+}, X_{+i}) el acuerdo esperado en cada categoría i. El acuerdo observado aparece en la diagonal de la matriz, mientras el esperado nos sirve para calcular el ajuste entre mapa y realidad que puede deberse al azar. El estadístico κ nos permite conocer si el grado de acuerdo observado se aleja o no significativamente del esperado al azar. En definitiva, este índice pretende evaluar si la clasificación ha discriminado las categorías de interés con exactitud significativamente mayor a la que se hubiera obtenido con una asignación aleatoria.

En el caso de la matrices de confusión que venimos analizando, el valor estimado de κ sería de 0,53 (tabla 8.2) y 0,70 (tabla 8.3), lo que indica que las clasificaciones son entre un 53 y un 70 % mejores de lo esperable al azar, respectivamente. Un valor de κ igual a 1 indica un acuerdo pleno entre la realidad y el mapa, mientras un valor cercano a 0 sugiere que el acuerdo observado es puramente debido al azar. Por su parte, un valor negativo supone también una clasificación pobre, si bien su sentido depende de otros factores externos, como el propio tamaño de la muestra.

Conviene indicar que el estadístico κ también puede calcularse para una determinada categoría de interés (es el denominado κ condicional), o se puede ponderar en función de algún criterio definido por el usuario. Como es lógico, no todas las confusiones son igualmente trascendentales. Por ejemplo, no es lo mismo que la confusión se produzca entre matorral y matorral-arbolado, que entre matorral y cultivos. En consecuencia, podemos obtener un valor ponderado de κ, a partir de unos pesos (w_{ij}) que asigne el usuario en función de la gravedad que estime se produce cuando se confunden las categorías i y j. El nuevo valor de κ sería:

$$\hat{k} = \frac{\sum_{i=1,n} w_{ii} X_{ii} / n - \sum_{i=1,n} w_{ij} X_{i+} X_{+i} / n}{1 - \sum_{i=1,n} w_{ij} X_{i+} X_{+i} / n} \quad [8.15]$$

Una de las aplicaciones más claras del índice κ es comparar clasificaciones realizadas por distintos métodos, con objeto de estudiar si difieren significativamente en cuanto a su grado de ajuste con la realidad (Fitzegarld y Lees, 1994). Para ello puede utilizarse la distribución normal para estimar intervalos de confianza (Skidmore, 1989):

$$z = \frac{|\hat{\kappa}_1 - \hat{\kappa}_2|}{\sqrt{\sigma^2_{\kappa 1} + \sigma^2_{\kappa 2}}} \quad [8.16]$$

El cálculo de la varianza de κ puede realizarse a partir de la siguiente fórmula (Congalton y Green, 1999):

$$\sigma^2_\kappa = \left(\frac{1}{n}\right)\left[\frac{\theta_1(1-\theta_1)}{(1-\theta_2)^2} + \frac{2(1-\theta_1)(2\theta_1\theta_2 - \theta_3)}{(1-\theta_2)^3} + \frac{(1-\theta_1)^2(\theta_4 - 4\theta_2^2)}{(1-\theta_2)^4}\right] \quad [8.17]$$

donde θ_1, θ_2, θ_3, y θ_4 se calculan de la forma siguiente:

$$\theta_1 = \left(\frac{1}{n}\right)\sum_{i=1,n} X_{ii} \quad [8.18]$$

$$\theta_2 = \left(\frac{1}{n^2}\right)\sum_{i=1,n} X_{i+} X_{+i} \quad [8.19]$$

$$\theta_3 = \left(\frac{1}{n^2}\right)\sum_{i=1,n} X_{ii}(X_{i+} + X_{+i}) \quad [8.20]$$

$$\theta_4 = \left(\frac{1}{n^3}\right)\sum_{i=1,n}\sum_{j=1,n} X_{ij}(X_{j+} + X_{+i})^2 \quad [8.21]$$

Este test puede emplearse para contrastar la validez efectiva de distintos métodos de clasificación (Chuvieco y Congalton, 1988; Fitzegarld y Lees, 1994). Por ejemplo, en el caso de los dos métodos de clasificación que venimos comentando (tablas 8.2 y 8.3), los valores estimados de κ son, respectivamente, 0,53 y 0,70 y los valores de varianza calculados son, respectivamente, de 0,000034 y 0,0000282. Por tanto, el valor z resultante de aplicar [8.16] sería 20,40. Este valor excede con creces el que cabría esperar aleatoriamente para un 95 % de probabilidad (el umbral sería 1,96). Puede con-

cluirse, por tanto, que ambas clasificaciones son significativamente distintas, o, dicho de otra forma, que la segunda es significativamente mejor que la primera.

Stehman (1999*a*) propone otros métodos para comparar dos clasificaciones de la misma o distintas zonas, utilizando la misma o distinta leyenda temática. Los métodos se basan en los valores de fiabilidad del usuario o en el conjunto de la matriz de confusión. Contempla la posibilidad de ponderar las categorías de partida, pero no incluye test de significación para validar si son estadísticamente distintas las diferencias encontradas. Sugiere, finalmente, que el estadístico kappa no resulta apropiado para las comparaciones al descartar el margen de aleatoriedad, que también puede incluir clasificaciones correctas, por lo que propone modificar ese estadístico considerando el número de categorías que se estén considerando.

7.5. Normalización de la matriz de confusión

En el caso de que se pretenda comparar dos matrices de confusión —ya sea generadas a partir de distintos métodos de asignación, ya de distintas imágenes o de distintos individuos—, κ puede indicarnos cuál de ellos es más efectivo en su conjunto. Ahora bien, en el caso de que se intente comparar la fiabilidad de dos mapas con distinto tamaño de muestreo, el estadístico κ no nos ofrece una valoración adecuada. Con vistas a solucionar este problema, Congalton (1984) propuso aplicar un procedimiento multivariado para normalizar una matriz cuadrada (Bishop *et al.*, 1975). Se trata de un método iterativo que ajusta los totales de filas y columnas a un valor común (+1), mediante sucesivos incrementos o reducciones en las celdillas de la matriz. El proceso se detiene cuando los marginales de cada fila y columna sumen +1,00, o un valor muy próximo a éste. En las tablas 8.4 y 8.5 se presentan las matrices normalizadas que venimos analizando, gracias a un programa cedido por el profesor Congalton.

Este proceso ofrece una nueva medida de la fiabilidad global. Basta calcular el valor medio de los elementos de la diagonal, que siguen indicando el acuerdo entre filas y columnas. Obviamente, la situación ideal sería que todos los elementos diagonales de la matriz fueran igual a 1. Esto indicaría un acuerdo perfecto entre reali-

Tabla 8.4. *Normalización de la matriz correspondiente a la tabla 8.2*

		Referencia								
		1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*
Clasificación	1	0,528	0,010	0,001	0,029	0,021	0,194	0,038	0,180	0,000
	2	0,030	0,527	0,166	0,000	0,137	0,042	0,052	0,046	0,000
	4	0,044	0,137	0,340	0,005	0,089	0,179	0,187	0,020	0,000
	5	0,007	0,008	0,005	0,847	0,080	0,010	0,030	0,013	0,000
	6	0,231	0,082	0,135	0,001	0,523	0,016	0,010	0,001	0,001
	7	0,058	0,137	0,123	0,101	0,100	0,244	0,097	0,085	0,054
	9	0,000	0,034	0,199	0,010	0,023	0,207	0,525	0,002	0,000
	A	0,099	0,056	0,026	0,001	0,021	0,093	0,055	0,649	0,000
	B	0,003	0,008	0,007	0,006	0,006	0,014	0,006	0,005	0,944

TABLA 8.5. *Normalización de la matriz correspondiente a la tabla 8.3*

		Referencia								
		1	*2*	*4*	*5*	*6*	*7*	*9*	*A*	*B*
Clasificación	1	0,804	0,040	0,031	0,001	0,042	0,000	0,002	0,080	0,001
	2	0,046	0,692	0,054	0,001	0,103	0,006	0,016	0,080	0,001
	4	0,010	0,011	0,708	0,002	0,069	0,115	0,083	0,001	0,001
	5	0,000	0,000	0,000	0,978	0,019	0,000	0,001	0,001	0,001
	6	0,015	0,225	0,055	0,001	0,698	0,001	0,003	0,001	0,001
	7	0,005	0,024	0,066	0,010	0,006	0,680	0,194	0,005	0,009
	9	0,074	0,004	0,076	0,001	0,050	0,174	0,621	0,000	0,001
	A	0,045	0,002	0,008	0,003	0,010	0,022	0,080	0,830	0,001
	B	0,002	0,002	0,001	0,004	0,002	0,001	0,001	0,002	0,986

dad y mapa, mientras una pobre clasificación se mostraría en valores diagonales muy bajos.

En este caso, el valor medio de las diagonales ofrece un porcentaje medio de fiabilidad entre el 57 y el 78 %. Por categorías se matizan más los valores aportados por las tablas originales, especialmente en lo que se refiere a acuerdos estimados perfectos, como es el caso de las áreas agrícolas que pasan del 100 % de exactitud a valores cercanos a 0,94.

Conviene tener en cuenta que estas medidas representan una estimación baja de la fiabilidad real, debido a las propias características del proceso de normalización. Es preciso considerar que la matriz de confusión es un caso muy peculiar de una tabla de contingencia, por cuanto aparecen con frecuencia celdillas con valores muy bajos o iguales a cero, ya que hay confusiones entre categorías muy poco probables. Como quiera que el proceso de normalización añade una pequeña cantidad a cada celdilla para evitar los ceros, las celdillas que expresan aciertos se ven infravaloradas frente al resto. Éste es el caso del modelo combustible 5, con una fiabilidad del 99,7 % en la tabla original (ensayo de clasificación mixta), que desciende a 97 % en la normalizada, como consecuencia del reducido tamaño de la muestra.

Pese a este problema, el proceso de normalización ofrece una visión complementaria a la recogida en la matriz original. Su medida de la fiabilidad global y para cada una de las categorías puede considerarse, con las reservas apuntadas, como una interesante alternativa a los métodos tradicionales, permitiendo comparar matrices con distinto número de muestras.

En la tabla 8.6 se recoge un resumen de los valores de fiabilidad, según los criterios expuestos en este capítulo, para las distintas matrices analizadas.

8. Verificación de análisis multitemporales

En el capítulo anterior consideramos el interés de los estudios de detección de cambios en teledetección. Lógicamente, ese tipo de estudios también requiere validar posteriormente los resultados. En este caso se trataría de ver la fiabilidad alcanzada

TABLA 8.6. *Comparación de los índices de verificación para varias clasificaciones digitales de la zona de Gredos (valores porcentuales: Salas y Chuvieco, 1995)*

Clasificación	*Fiabilidad global*	*Índice κ*	*Fiabilidad normalizada*
No supervisada (TM + información auxiliar)	62	53	57
No supervisada (TM)	60	50	56
Supervisada	62	54	60
Mixta	75	70	78

por una interpretación de dos fechas simultáneamente, lo que implica considerar la fiabilidad de cada fecha por separado y de las dos en conjunto. Esto complica notablemente el análisis de las matrices de confusión, ya que a los factores de ruido potencial antes comentado le añadimos la propia incertidumbre del ajuste entre fechas y la dificultad de obtener información de referencia para períodos a veces muy separados en el tiempo.

Sintetizando estos aspectos podemos señalar como principales novedades de la verificación cuando se aplica a estudios de detección de cambios las siguientes (Fernández-Gustiz, 2001):

— Aumento del número de categorías en la matriz de error. El número potencial de categorías («estable», «de», y «a») para dos fechas es el cuadrado del número de categorías en una única fecha o imagen. Todas estas clases deben de ser consideradas en la evaluación del error, por lo que finalmente la matriz de confusión tendrá n^4 celdillas, siendo n el número de clases de partida para una fecha (tabla 8.7).

— Mayor complejidad en el esquema de muestreo, al aumentar mucho el número de categorías a verificar. Puesto que, además, será frecuente que algunos de los potenciales cambios sean muy infrecuentes o imposibles (por ejemplo, de áreas urbanas

TABLA 8.7. *Matriz de confusión para la detección de cambios*

			Referencia								
			Estable			*Cambio*					
			AB	*BB*	*CC*	*AB*	*AC*	*BA*	*BC*	*CA*	*CB*
Clasificación	*Estable*	AA	1	3	3	5	5	5	5	5	5
		BB	3	1	3	5	5	5	5	5	5
		CC	3	3	1	5	5	5	5	5	5
	Cambio	AB	4	4	4	2	6	6	6	6	6
		AC	4	4	4	6	2	6	6	6	6
		BA	4	4	4	6	6	2	6	6	6
		BC	4	4	4	6	6	6	2	6	6
		CA	4	4	4	6	6	6	6	2	6
		CB	4	4	4	6	6	6	6	6	2

A, B, C son distintas categorías temáticas. Ver texto para explicación. Adaptado de Congalton y Green (1999) y Biging *et al.* (1998).

a láminas de agua), tendremos que aumentar notablemente el tamaño de la muestra para poder verificar esos cruces. En estas ocasiones, el muestreo estratificado o el basado en información auxiliar puede ser una buena alternativa (Biging *et al.*, 1998).

— Dificultad para obtener la información de referencia en fechas pasadas. Como es lógico, en la mayor parte de los casos no tendremos información de detalle de las coberturas terrestres para una fecha distante, tal vez varios años, de la actualidad. Fotografías aéreas o documentos cartográficos de fecha similar a la que pretende emplearse pueden paliar este problema, aunque, como ya hemos indicado, no siempre resultan plenamente fiables.

Cuando se pretende verificar una detección de cambios, la matriz de confusión se complica notablemente. Para un sencillo ejemplo de tres categorías en las dos fechas tendríamos 9 categorías de posible dinámica (los posibles cruces entre las dos fechas), y por tanto la matriz de confusión contaría con 81 celdas (las nueve posibilidades reales cruzadas con las 9 posibles asignadas por la interpretación de la imagen). En esa matriz de confusión multitemporal se incluiría la verificación tanto de las clases estables, aquellas en donde se haya mantenido la misma categoría entre fechas, como de las clases dinámicas. Todos esas posibilidades requieren validación. Por tanto, la matriz de confusión incluirá la tabulación de píxeles que nuestro mapa de cambios señala como «de clase *X* a clase *Y*», mientras en la realidad son ése u otro tipo de transiciones. Como en el caso de la matriz de confusión simple, en la diagonal se incluirán las detecciones de cambio correctas (cuando se detectó como estable o como un cierto cambio cuando en realidad así era), y fuera de la diagonal los cambios erróneos (detectar como estable cuando era cambio, o viceversa, o detectar un cambio entre dos categorías, cuando en realidad se produjo entre otras).

Siendo un poco más específicos, podemos explicar mejor la estructura de una matriz de confusión multitemporal utilizando la notación de Biging *et al.* (1998), que recoge la tabla 8.7. Las celdillas anotadas con 1 indicarían áreas detectadas como estables, cuando ciertamente lo son, mientras que las que tienen un 2 señalarían áreas correctamente clasificadas como de un determinado cambio. La suma de ambos, 1 y 2, indicaría la fiabilidad global de la detección de cambios efectuada por el intérprete. El resto suponen errores, que vendrían definidos por varias posibilidades: el 3 señala las zonas señaladas como estables pero en una categoría que no les corresponde; el 4 identifica sectores en donde se señalaron cambios cuando en realidad se mantuvo la misma categoría (se trata, por tanto, de errores de comisión, al identificar como cambio lo que no fue tal); el 5 determina cambios reales no discriminados (por tanto, errores de omisión), y el 6 cambios incorrectamente identificados (se detectan como cambios, pero no en la categoría correcta, lo que implica error de omisión o de comisión, dependiendo de la clase que consideremos).

Las medidas de fiabilidad global y por categorías son las mismas, por otro lado, que las señaladas para la matriz unitemporal.

CAPÍTULO 9

TELEDETECCIÓN Y SISTEMAS DE INFORMACIÓN GEOGRÁFICA

«Detrás de la máscara de la libertad se esconde frecuentemente la dejadez, el deseo de no implicarse.»

SUSANA TAMARO, *Donde el corazón te lleve*

1. Necesidad de los SIG

Buena parte de los usuarios de la teledetección espacial tienen como objetivo último de su trabajo integrar la información resultante con otras variables geográficas, de cara a obtener una visión más sintética de las características de un determinado territorio. Este enfoque resulta de gran interés de cara, por ejemplo, a una evaluación más completa de los recursos que nos brinda ese espacio, o a abordar una planificación más acorde con sus potencialidades. En cualquier caso, resulta cada vez más frecuente que los resultados de la interpretación de las imágenes no supongan la culminación del trabajo, sino más bien una fase en la recopilación de información sobre el área de interés, por lo que resulta preciso conectar esos resultados con otras variables territoriales.

Este tipo de enfoques se han visto notablemente favorecidos por el desarrollo de las tecnologías orientadas al almacenamiento, análisis y salida gráfica de la información espacial. En este marco resultan protagonistas los denominados Sistemas de Información Geográfica (SIG, o, en la terminología anglosajona, *Geographic Information Systems, GIS*). Los SIG pueden definirse como programas que almacenan, gestionan, manipulan y representan gráficamente datos con un algún tipo de componente espacial (Bosque, 1997; Burrough y McDonell, 1998; Cebrián, 1988). Esto significa que la información que albergan está referenciada geográficamente, ya se trate de mapas, estadísticas o datos climáticos sobre un territorio concreto, por lo que todas estas variables pueden relacionarse mutuamente de formas muy diversas (fig. 9.1). Por cuanto la información que contienen se almacena en formato digital, los SIG aprovechan las posibilidades analíticas de los ordenadores, facilitando múltiples operaciones que resultan difícilmente accesibles por medios convencionales: generalización cartográfica, integración de variables espaciales, modelado del relieve, análisis de vecin-

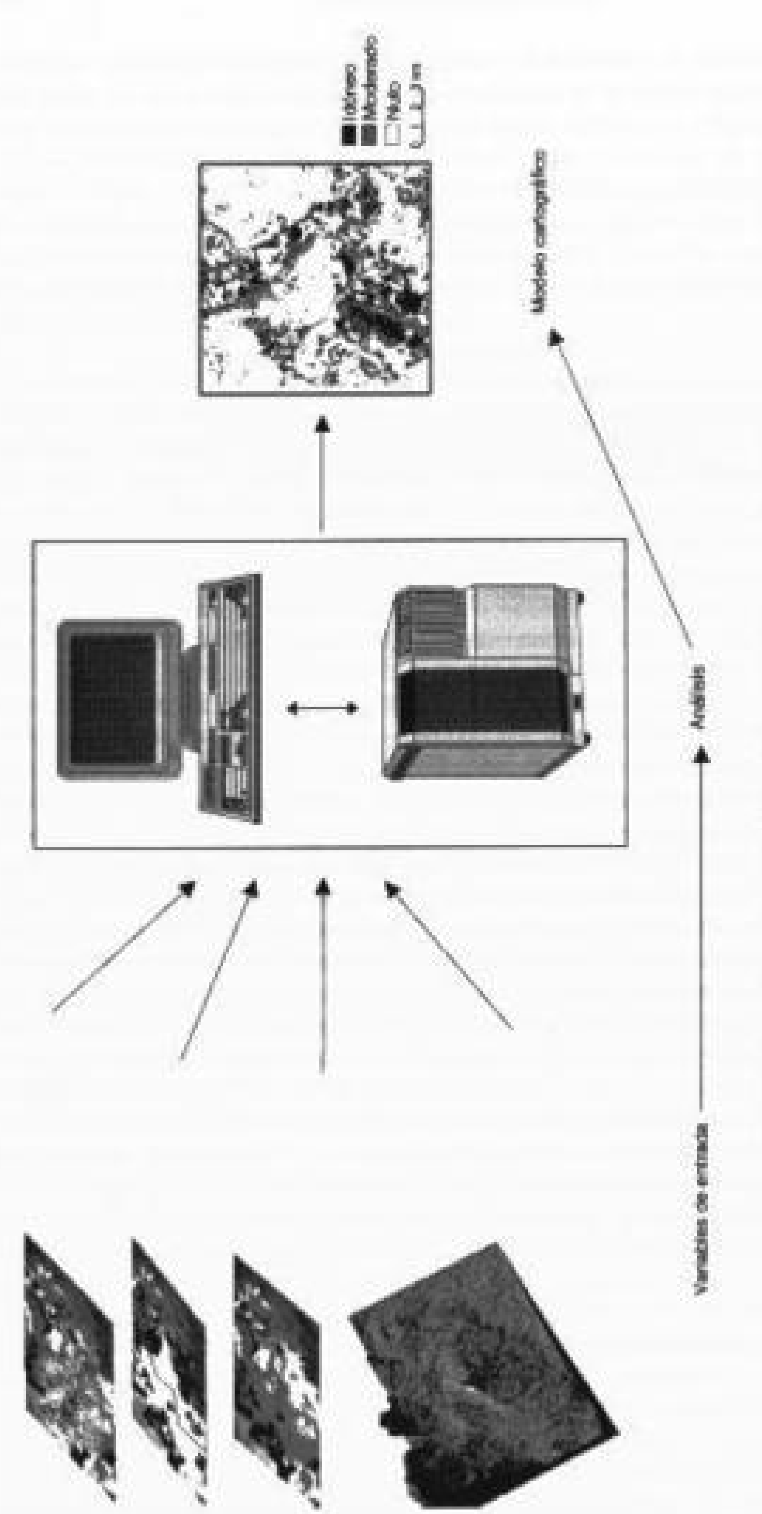


FIG. 9.1. *El enfoque integrado de los Sistemas de Información Geográfica.*

dad, etc. Además, los SIG permiten almacenar esa información espacial de forma eficiente, simplificando su actualización y acceso directo al usuario. En definitiva, amplían enormemente las posibilidades de análisis que brindan los mapas convencionales, además de facilitar su almacenamiento y visualización.

Un SIG está compuesto por unos equipos físicos, especializados en el manejo de información espacial, y una serie de programas que, conectados con aquéllos, permiten realizar múltiples transformaciones a partir de las variables espaciales introducidas al sistema. El SIG no es un producto cerrado en sí, sino un compuesto de elementos diversos: ordenador, digitizador, trazador gráfico, impresoras, y distintos paquetes de programas, orientado hacia una finalidad específica. También existen SIG comerciales, que intentan recoger todos estos productos bajo una misma estructura, si bien lo más habitual —en el momento presente— sea la comercialización exclusiva de los programas, que pueden adaptarse a soportes físicos muy variados.

La amplia disponibilidad de manuales sobre SIG (Aronoff, 1989; Bosque, 1997; Burrough y McDonell, 1998; Comas y Ruiz, 1993; Gutiérrez y Gould, 1994; Juppenlatz y Tian, 1996; Maguire *et al.*, 1991; Sancho *et al.*, 1993; Star y Estes, 1990; Tomlin, 1990) nos aconseja prescindir de comentarios sobre los componentes y principales funciones de un SIG, que dejamos al lector interesado para su consulta. En consecuencia, nos centraremos con mayor atención sobre las relaciones entre los SIG y la teledetección, así como sobre las modalidades concretas a través de las cuales ambas pueden integrarse.

2. Paralelismo y convergencia

Podemos afirmar que los orígenes de la teledetección y los SIG siguieron una trayectoria bastante paralela. En otras palabras, ambas técnicas surgieron como disciplinas independientes, sólo unidas por su orientación medioambiental. El primer SIG, diseñado en Canadá en los años sesenta, pretendía facilitar la labor de conservación de los ingentes recursos de que dispone ese país. Sin embargo, se dirigía más hacia el análisis que hacia la recogida de información espacial, que se suponía disponible por otras fuentes convencionales. Esta dimensión cartográfica de los SIG se refuerza en los años setenta, especialmente a través del trabajo del *Laboratory for Computer Graphics* de la Universidad de Harvard, que pretendía resolver los problemas de geometría computacional implicados en el proceso de esta información cartográfica (Coppock y Rhind, 1991).

Por otro lado, la teledetección durante los años sesenta se convirtió en una fuente más de información medioambiental, considerada en sí misma y no tanto en su conexión con otras variables espaciales. Se pretendía facilitar una cartografía e inventario de algún fenómeno de interés, culminando el trabajo con la obtención de dichos productos.

Ahora bien, el propio desarrollo de las técnicas de interpretación, especialmente a partir de 1972 cuando se comienzan a difundir las primeras imágenes Landsat, permitió ampliar ese planteamiento. En un primer momento, la relación entre ambas técnicas se centró en acudir a variables cartográficas para complementar a la clasificación digital de las imágenes (Strahler *et al.*, 1978). Un paso más allá vino dado, a inicios de los años 80, cuando comienza a considerarse la teledetección como auxiliar de un SIG, sirviendo como una fuente más de información para un estudio integrado sobre el territorio. Algunas áreas de aplicación donde este planteamiento resultó más evidente

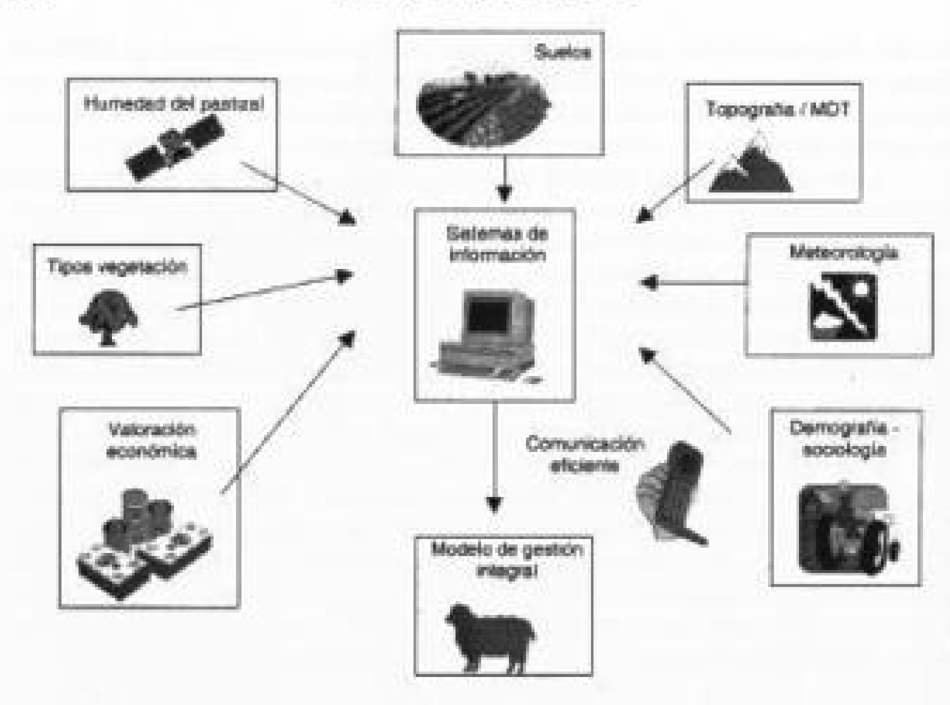


FIG. 9.2. *Modelo de gestión de la información espacial para una evaluación agrícola.*

fueron el manejo de recursos forestales (Martin, 1985), agrarios (Wheeler y Ridd, 1985), y los sistemas de prevención de incendios forestales (Yool *et al.*, 1985).

Esta situación se ha mantenido hasta la actualidad, constituyéndose los SIG como elementos protagonistas del análisis espacial, al integrar la información geográfica, sea cual sea la procedencia (fig. 9.2). En este sentido, la teledetección podría considerarse como una fuente más de información para un SIG, junto a otras más convencionales (cartografía analógica, datos censales, sistemas automáticos de captura de datos, etc.) o recientes (Sistemas de Posicionamiento Global, GPS, sensores terrestres de adquisición de datos, etc.). Al ser necesario superar algunos escollos en la manipulación de datos tan diversos, que no se contemplaron inicialmente en el diseño de los SIG (volumen de almacenamiento, estructuras de datos, herramientas de análisis), algunos autores son partidarios de acuñar nuevos términos como sería el de Sistemas Integrados de Información Geográfica (*Integrated Geographic Information System, IGIS*: Davis y Simonett, 1991), para designar a estos nuevos SIG.

La creciente convergencia entre la teledetección y los SIG se justifica, entre otras, por las siguientes razones:

1. Ambas poseen una clara orientación territorial.
2. Cuentan con similares requerimientos, tanto en *hardware* como en *software*.
3. Se desarrollan por y para el mismo tipo de profesionales.
4. Responden a demandas de investigación similares, como es el caso del análisis de errores, la estructura y acceso a los datos, el desarrollo del entorno informático y la metodología de interpretación (Star *et al.*, 1991).

La integración tampoco está exenta de problemas, ligados a la disponibilidad de datos (costes, nivel de resolución espacial, espectral y temporal), a la educación y al acceso a los equipos, entre otros (Lauer *et al.*, 1991). No obstante, en los últimos años, parece confirmarse una tendencia hacia la convergencia entre ambas técnicas.

3. Requisitos técnicos comunes

Tanto los SIG como la teledetección (si se aborda una interpretación digital de los datos) requieren unos equipos físicos especializados en el manejo de información espacial, así como una serie de programas que, conectados con aquellos, permitan realizar múltiples transformaciones de datos. Los componentes que requiere la interpretación digital de imágenes son, en gran medida, comunes a los que requieren los programas SIG. La distinción principal atañe no tanto a la teledetección y los SIG, sino más bien a los SIG basados sobre formatos ráster frente a los basados en formatos vectoriales. Los primeros tienen una gran afinidad con el tratamiento digital de imágenes, ya que la estructura de datos es muy similar. Por el contrario, los SIG vectoriales manejan la información con características muy distintas, aunque en ocasiones esos procesos sean opacos al usuario, por lo que requieren unidades de entrada peculiares (digitalizador), que apenas tienen importancia en el tratamiento digital de imágenes.

En la tabla 9.1 se presenta un resumen de los componentes físicos más comunes en tratamiento digital de imágenes, SIG ráster y SIG vectoriales. Como puede observarse, las afinidades son claras en cuanto a las características del ordenador soporte, recomendándose que sea suficientemente potente como para procesar la gran cantidad de información que ambas técnicas manejan. De igual forma, se precisa una amplia capacidad de almacenamiento, para albergar una gran cantidad de datos, ya sean imágenes de satélite o mapas, con especial énfasis en el primer caso (Ferns y Press, 1988). En cuanto a los periféricos, las unidades de entrada de información son bastante comunes a los SIG vectoriales y ráster (tableta digitizadora y escáner), mientras la teledetección prácticamente siempre trabaja con imágenes digitales. Para manejar los programas, ambas técnicas emplean los mismos componentes (teclado, ratón o minitableta digitizadora). Finalmente, en cuanto a los periféricos de salida gráfica, los SIG vecto-

TABLA 9.1. *Afinidades entre la Teledetección y los SIG en cuanto a componentes físicos (se indica cuando el componente es muy comúnmente utilizado +, o sólo de modo esporádico*)*

Componente	*Teledetección*	*SIG ráster*	*SIG vectorial*
Ordenador central	+	+	+
Memoria externa	+	+	+
Unidades de respaldo	+	+	+
Digitalizador	*	+	+
Escáner	*	+	+
Impresoras de inyección	+	+	*/+
Filmadoras	+	+	+

riales presentaban hasta hace unos años un carácter específico, al utilizar trazadores gráficos *(plotters)* de plumillas, que no tenían aplicación con formatos ráster. Actualmente, estos equipos han desaparecido, y tanto los SIG vectoriales como los ráster y la teledetección comparten los mismos equipos (impresoras o trazadores de inyección de tinta, electrostáticas y filmadoras).

Respecto al *software*, las relaciones con la teledetección también son muy diferentes si se trata de SIG ráster o vectoriales. Ambos cuentan con procesos muy similares a los aplicados en teledetección: visualización, correcciones geométricas, superposición de capas, operaciones aritméticas o filtrajes. Ahora bien, la forma concreta de resolver estos procesos es muy distinta en ambas estructuras de almacenamiento. Una transformación de mapas en un SIG vectorial implica resolver una serie de problemas geométricos bastante complejos, ya que precisa una definición topológica de cada una de las transformaciones (Bosque, 1997; Burrough y McDonell, 1998). Por su parte, la estructura ráster está muy cercana a la de una imagen digital, con la sola variante de que ésta presenta una escala de intervalo (es una variable cuantitativa, con una escala comprendida entre 0 y 2^n, siendo *n* el número de bits de la resolución radiométrica del sensor), mientras las almacenadas en un SIG son con frecuencia nominales (corresponden a información categorizada: tipos de suelo o vegetación, por ejemplo). Esto explica que algunos procesos sean específicos de cada técnica. Los realces del contraste, filtros, índices de vegetación, análisis de componentes principales, o clasificación numérica sólo tienen sentido cuando se trata de variables medidas en una escala numérica continua (ND, valores de radiancia, temperatura o reflectividad de la imagen),[1] mientras los filtros modales, las operaciones lógicas o los análisis de proximidad exigen una categorización previa de la información.[2]

4. Los SIG como apoyo a la teledetección

A lo largo de esta obra hemos visto en diversos capítulos la importancia de contar con información auxiliar para corregir algunos errores incluidos en las imágenes, así como para refinar la clasificación de diversas categorías. Modelos digitales de elevación (MDE), mapas de suelos o climáticos, límites administrativos, regiones ecológicas o parcelas catastrales son ejemplos de variables cartográficas que pueden enriquecer notablemente el análisis digital de las imágenes.

Lo más común en los últimos años es que esta información auxiliar provenga de un SIG, cuyos datos estén previamente georeferenciados a las imágenes o viceversa, mediante los oportunos procesos de corrección. Esa información no espectral puede incorporarse al tratamiento de las imágenes en varias fases:

1. Previamente a la clasificación. Algunos campos de gran interés son la incorporación de un MDE en sectores de topografía accidentada, de cara a refinar la corrección geométrica y radiométrica de las imágenes, paliando la distorsión en ellas incluida por el relieve: efecto de sombras y geometría de adquisición, fundamentalmente. También puede ser conveniente incorporar información auxiliar para estratificar la imagen en sectores más homogéneos —por ejemplo, desde el punto de vista de las condiciones bioclimáticas o de la fisiografía local— con objeto de clasificar digitalmente áreas más similares, evitando la excesiva dispersión que puede presentarse en algunas categorías (Strahler, 1981).

2. Durante la clasificación. En esta fase, los datos auxiliares pueden ser de gran ayuda, tanto en la correcta delimitación de los campos de entrenamiento —si se opta por la clasificación supervisada—, como en el reconocimiento temático de los grupos espectrales *(clusters)*, caso de emplear la no supervisada. Ya hemos indicado que buena parte de la calidad de los resultados de la clasificación depende de delimitar apropiadamente las áreas de entrenamiento, por lo que cualquier información auxiliar que ayude a su mejor selección será de gran utilidad. Si, por el contrario, se opta por la clasificación no supervisada, la información almacenada en un SIG también resulta muy útil, por ejemplo de cara a etiquetar los grupos espectrales definidos por el ordenador (Loveland *et al.*, 1991).[3]

Las variables auxiliares pueden emplearse también como nuevas bandas para la clasificación, aportando una dimensión no-espectral para la discriminación de determinadas clases. Éste es el caso de incluir un MDE como variable adicional en la clasificación (Franklin *et al.*, 1986), reduciendo así el efecto de la topografía local, si no se han abordado correcciones radiométricas previas. En los clasificadores convencionales, esta variable puede ser fácilmente introducida, ya que está medida, al igual que las imágenes, en escala de intervalo. Otras variables geográficas, como suelos o regiones biogeográficas, son más complicadas de integrar en esos criterios de clasificación, aunque sí podrían incluirse en aquellos que no requieran variables cuantitativas (por ejemplo, los basados en árboles de decisión).

3. Después de la clasificación. Una primera aportación de los SIG en esta fase atañe a la propia verificación de las clasificaciones. La información almacenada en estos sistemas puede facilitar la localización de los campos de verificación, de cara a valorar cuantitativamente la fidelidad alcanzada en la clasificación.

Además, las variables auxiliares pueden servir para re-asignar algunas categorías, en caso de que no hayan sido discriminadas sólo a partir de información espectral (Hutchinson, 1982). Por ejemplo, algunos cultivos o especies forestales, que contaran con similar comportamiento espectral, podrían discriminarse gracias al tipo de suelos sobre los que se asientan. De esta forma, bastaría contar con esa variable auxiliar, suelo, para que la identificación fuera mucho más certera. Un ejemplo de este enfoque de clasificación integrado es el mapa global de cobertura del suelo de EE. UU., realizado a partir de una larga secuencia de imágenes AVHRR y diversas variables biogeográficas. A partir de las imágenes se obtuvieron los grupos espectrales básicos, que fueron etiquetándose, y en su caso discriminándose, a partir de mapas de regiones climáticas, suelos, áreas ecológicas, modelos digitales de elevación, etc., para el conjunto del país (Brown *et al.*, 1993).

1. Lógicamente, cuando en el SIG se analicen variables cuantitativas (precipitación, temperatura, altitud, pendiente, etc.) también pueden aplicarse este tipo de técnicas de transformación digital.
2. Sobre las escalas de medida pueden consultarse, entre otros, Bosque (1997) y Tomlin (1990).

3. Este aspecto resulta especialmente problemático cuando se trata de bases de datos globales, que incorporan además la propia diversidad de definiciones y formatos cartográficos que ofrece cada país (Chuvieco, 1992; Rhind y Clark, 1988).

Otro aspecto de gran interés hace referencia al error de frontera, que ya comentamos en el anterior capítulo, y aparece con frecuencia en áreas de transición en donde la definición de un píxel puede resultar ambigua, ya que, de hecho, corresponde a la respuesta espectral de dos o más cubiertas distintas. Un procedimiento para reducir la influencia de este error sería incluir, desde un SIG, los bordes que definen las distintas parcelas, modificando la pertenencia de los píxeles situados en esos límites.

4. Un último aspecto en donde la información de un SIG facilita un valor añadido a la teledetección hace referencia a la visualización de resultados. La integración de la teledetección y los SIG permite ampliar notablemente las posibilidades gráficas de la cartografía convencional, facilitando su análisis visual al público profano. Algunas experiencias en esta línea son la realización de perspectivas tri-dimensionales o vuelos simulados, a partir de una imagen original o clasificada y de un modelo digital de elevación (fig. 21*).

5. La teledetección como fuente de datos para un SIG

5.1. El acceso a la información geográfica

Entre los siglas que definen a los SIG, a nuestro juicio resulta evidente que la más importante es la central, esto es la Información, puesto que el término Geográfica no es más que un calificativo de ésta, y el de Sistemas puede aplicarse a otras muchas aplicaciones informáticas. Los SIG, en definitiva, sólo son herramientas para la mejor gestión de la información disponible sobre el territorio: no permiten por sí solos generarla. En consecuencia, si la información almacenada en un SIG no es suficientemente fiable, está anticuada o es incompleta, de nada sirve contar con un soporte físico o lógico muy poderoso, pues ese SIG será de poco provecho en la solución de los problemas reales que afectan a las personas de un determinado territorio. Los SIG sin información de suficiente calidad son únicamente fuegos artificiales, vistosos pero inútiles.

En definitiva, resulta imprescindible que las capas de información que integran un determinado SIG (litología, relieve, suelos, datos climáticos, vegetación, cultivos, datos censales, etc.) tengan la resolución y el nivel de fiabilidad adecuado, y estén debidamente actualizadas. Puesto que esas variables son comúnmente generadas por distintas agencias, que, a su vez, pueden haber contratado el trabajo a múltiples intérpretes, la integración de esas variables en el SIG puede ser muy compleja, tanto desde el punto de vista temático como geométrico (Mounsey, 1991). En consecuencia, no sólo es necesario que exista una buena información geográfica, sino también que pueda integrarse en una base de datos coherente. Esto implica coordinación, tanto entre los diversos grupos que han generado cada variable (en el seno de una institución), como también entre las distintas instituciones con responsabilidades cartográficas.

Con mucha frecuencia, ambos aspectos no se garantizan adecuadamente, lo que dificulta considerablemente la operatividad de un SIG. Por un lado, pueden faltar determinados inventarios cartográficos, tan vitales para la planificación física, como son la cartografía de suelos o geomorfológica. Por otro, pueden presentarse desconexiones entre los organismos que generan la información. Esto implica, en muchas ocasiones, duplicar esfuerzos y presupuestos, ya sea porque la información generada por estos organismos no resulte intercambiable, porque no se han arbitrado canales apropiados para la distribución pública de esa información, o, simplemente, porque no se conoce.

La teledetección espacial, por sí sola, no puede resolver estos problemas, pero puede contribuir a paliarlos al facilitar datos de libre adquisición, en formatos estándar, y plenamente actualizados. Comprendiendo el alto coste de generar información geográfica de calidad, la inversión en imágenes de satélite puede justificarse plenamente, sin olvidar que en muchas ocasiones lo verdaderamente caro es no disponer de la información necesaria para tomar decisiones cuando resulta imprescindible hacerlo (en situaciones de emergencia, por ejemplo: Camarasa *et al.*, 2001)

Existen diversos medios para generar información geográfica, desde el tradicional trabajo de campo (insustituible todavía en muchas ocasiones), hasta los sensores terrestres (medidores de temperatura, humedad o polución atmosférica, estaciones de aforo, etc.), sistemas de posicionamiento global (GPS) y teledetección aérea o espacial. Todos ellos son medios necesarios, que convendrá seleccionar en función de la variable que quiera obtenerse y de los propios requisitos del trabajo (presupuesto, tiempo de obtención, fiabilidad requerida, etc.). Sintetizando las cosas, las ventajas de la teledetección como fuente de datos para un SIG se centran principalmente en la obtención de algunas variables de interés (fase de inventario cartográfico), y en la actualización de información ya generada. A continuación analizamos con más detalle ambos aspectos.

5.2. Fase de inventario

La teledetección, como hemos visto en capítulos precedentes, puede resultar una herramienta idónea para cartografiar determinadas variables: temperatura del agua del mar, contenido en clorofila, cobertura de nieve, rendimientos del cultivo, ocupación del suelo, etc., y la lista se está continuamente ampliando ante la disponibilidad de nuevos sensores, con mayor resolución espacial, espectral o temporal (Baker, 2001). En algunos casos, estas aplicaciones abarcan campos ya recogidos por otros métodos más tradicionales, como la fotografía aérea o los trabajos de campo. El empleo de la teledetección, en estas situaciones, se justifica si ofrece menores costes y/o mayor rapidez que los medios ya utilizados (por ejemplo, por tratarse de áreas inaccesibles), manteniendo la exactitud requerida.

En otros casos, las aplicaciones que ofrece la teledetección son relativamente originales, pues resultan inasequibles, a un precio razonable, con las técnicas convencionales (cartografía de la clorofila en el agua, detección de vertidos incontrolados de petróleo). Habitualmente se trata de variables que sólo pueden medirse en una red de puntos más o menos dispersa sobre el territorio, lo que supone aplicar técnicas de interpolación/extrapolación para obtener la distribución espacial completa de esa variable. Aunque la gama de estas técnicas es muy variada (Burrough y McDonell, 1998, cap. 5-6), todas ellas incluyen distintas fuentes de error. Por su parte, las imágenes cubren exhaustivamente el territorio (a la resolución espacial del sensor), por lo que pueden ofrecer una visión espacial mucho más adecuada que las técnicas de interpolación, especialmente si la red de observatorios no cubre algunos sectores críticos del área de estudio (Sánchez y Chuvieco, 2000).

Otro contexto en donde la teledetección resulta la alternativa más razonable afecta a la generación de bases de datos globales, ya que se trata de un medio de observación que cubre casi todo el planeta, con el mismo o similar sensor, y a intervalos regulares. Esto facilita la generación de algunas variables ambientales para espacios muy heterogéneos y en condiciones de gran consistencia (DeFries y Townshend, 1994; Foody, 2001).

Además de en estos ámbitos, la teledetección puede ser una alternativa muy conveniente cuando sólo se disponga de información analógica, que sea preciso digitizar, siempre que la escala de trabajo y el nivel de desagregación de la leyenda sean abordables a partir de la imagen de satélite. Al tratarse de información ya digital, las imágenes de satélite pueden integrarse con relativa facilidad, como luego veremos, en un SIG, obviando la labor de digitización, imprescindible a partir de la fotointerpretación o la cartografía temática convencional. No hemos de olvidar que la mayor parte de los países del mundo no cuentan con una cartografía digital suficientemente extendida (Rhind y Clark, 1988): la mayor parte de la información geográfica disponible está constituida por mapas en papel, frecuentemente de distintas escalas y proyecciones. Numerosos autores están de acuerdo en que la digitización de esta cartografía resulta la labor más compleja y costosa en el establecimiento de un SIG (Burrough y McDonell, 1998; Star y Estes, 1990). Además, es la partida más costosa en el desarrollo y mantenimiento de la base de datos (hasta un 70% en la experiencia del servicio forestal norteamericano: Lachowski *et al.*, 1992).

Existen diversos métodos para convertir estos mapas a formato numérico, pero ninguno, hoy por hoy, es completamente satisfactorio. La codificación manual no representa una solución operativa. El empleo de una mesa de digitización facilita la obtención automática de coordenadas, pero también resulta un proceso lento y laborioso que requiere una detallada depuración de errores. La digitización automática mediante escáner es el recurso más habitual para organismos cartográficos. Sin embargo, precisa un importante trabajo de edición para pulir posibles errores en la codificación de líneas o en la formación de la topología del mapa. Por último, las cámaras de vídeo o los restituidores digitales pueden cumplir misiones específicas —por ejemplo, en la obtención del modelo digital de elevaciones—, pero no resuelven la entrada de otras variables de gran interés en estudios medioambientales.

Además de la lentitud y elevado coste del proceso, la entrada de información en un SIG no está exenta de errores. Las causas más importantes de estos defectos son:

1. Las inexactitudes en la digitización (polígonos mal etiquetados, desplazamiento de líneas, generalización de elementos).
2. La falta de criterios homogéneos entre las personas que compilan la información base.

En consecuencia, no se trata de introducir indiscriminadamente la cartografía disponible, sino de seleccionar la más precisa y duradera, confiando a otros métodos la obtención de nuevas variables o la actualización de las existentes.

5.3. El problema de la actualización

Realizar un inventario cartográfico es sólo una primera parte en la generación de un SIG operativo. El paso siguiente es mantener esa información al día, recogiendo aquellos cambios que se hayan producido entre la fecha de realización del mapa y la actual. En muchas ocasiones, la cartografía que pretende introducirse en un SIG no representa fidedignamente el estado actual del territorio, sino una situación obsoleta, que puede invalidar cualquier análisis posterior de esa información. Datos desactualizados tienen las mismas consecuencias que datos erróneos: llevan a decisiones equivocadas, que pueden tener un efecto social o ambiental de gran trascendencia. Por ello se reconoce generalmente que la actualización de información, pese al notable esfuerzo que supone, debe incluirse en la gestión permanente de un SIG (Aronoff, 1989; Camarasa *et al.*, 2001).

Como hemos visto a lo largo de esta obra (especialmente en cap. 7, apdo. 3), las imágenes adquiridas desde el espacio ofrecen magníficas posibilidades para la actualización de datos, al ofrecer adquisiciones sistemáticas y en condiciones similares de observación. Esto permite obtener una visión actualizada de la superficie que se observa, así como seguir la evolución temporal de determinados fenómenos muy dinámicos: crecimiento urbano, estado de los cultivos, inundaciones, erupciones volcánicas, etc. Más aún, la agilidad que proporciona la interpretación digital permite obtener resultados en fecha bastante cercana a la obtención de la imagen, reduciéndose el periodo entre la realización y la disponibilidad del inventario.

Además de servir para generar nuevas variables, las imágenes espaciales también permiten actualizar la información ya almacenada en el SIG (Smits y Annoni, 1999; Zuylen, 1978). Las modalidades de actualización pueden ser diversas. La más sencilla pasa por utilizarlas como «fondo» al que se superponen los límites de las áreas temáticas ya archivadas en el Sistema, una vez que ambos documentos ajusten entre sí con precisión (fig. 9.3). Esa simple superposición visual facilita mucho la actualización de los recintos archivados, incorporando aquellos cambios ocurridos entre la fecha del inventario original y la correspondiente a la nueva imagen. Los ejemplos en el campo de la cartografía urbana son muy numerosos: nuevas construcciones, infraestructuras, ejes viarios, etc., aunque también son destacadas en otras aplicaciones, como es el caso de la actualización de espacios forestales cuando se ha producido un incendio, los cambios de cultivo, o la incorporación de nuevos caminos, carreteras y embalses.

6. Integración de imágenes en un SIG

Si bien las imágenes espaciales se adquieren en formato digital, también es posible abordar una interpretación visual de las mismas, por lo que la integración de imágenes espaciales en un SIG puede realizarse de distintas formas (fig. 9.4; Campbell, 1996):

1. Digitizando un mapa temático obtenido a partir de la interpretación visual de la imagen.
2. Digitizando un mapa temático en papel obtenido a partir de la clasificación digital de la imagen.



FIG. 9.3. *Una imagen de satélite puede usarse como soporte gráfico para actualizar información geográfica.*

3. Superponiendo visualmente la información de un SIG vectorial sobre una imagen de satélite, digitizando sobre la imagen los sectores que hayan cambiado.
4. Incorporando directamente el fichero generado por la clasificación digital de la imagen.
5. Integrando en el SIG los valores digitales originales o los obtenidos a partir de una transformación de la imagen (índices de verdor, estimación de la temperatura del agua, albedo, etc.).

Resulta obvio que estas dos últimas son las opciones más convenientes, puesto que proporcionan información al SIG obviando la tarea de digitización. Como ya hemos visto, la clasificación digital de imágenes en teledetección proporciona un fichero numérico, en donde cada píxel cuenta con un valor entero que indica la categoría en la cual se incluyó. Por tratarse de una información digital, la integración en un SIG no resulta muy problemática.

La forma concreta de llevar a cabo esta integración depende, primordialmente, de la estructura de almacenamiento del SIG y del tipo de interpretación de la imagen que se haya efectuado. Si se optó por una interpretación visual y posterior digitización, la conexión con un SIG de tipo vectorial es bastante directa, mientras requeriría una conversión vectorial a ráster para integrarse en un SIG con este formato. En ambos casos, la entrada de información es similar a la aplicable en el caso de cartografía convencional, siendo las ventajas de la teledetección su mayor accesibilidad temporal y menores errores geométricos.

Como hemos indicado, resulta mucho más conveniente la conexión entre las imá-

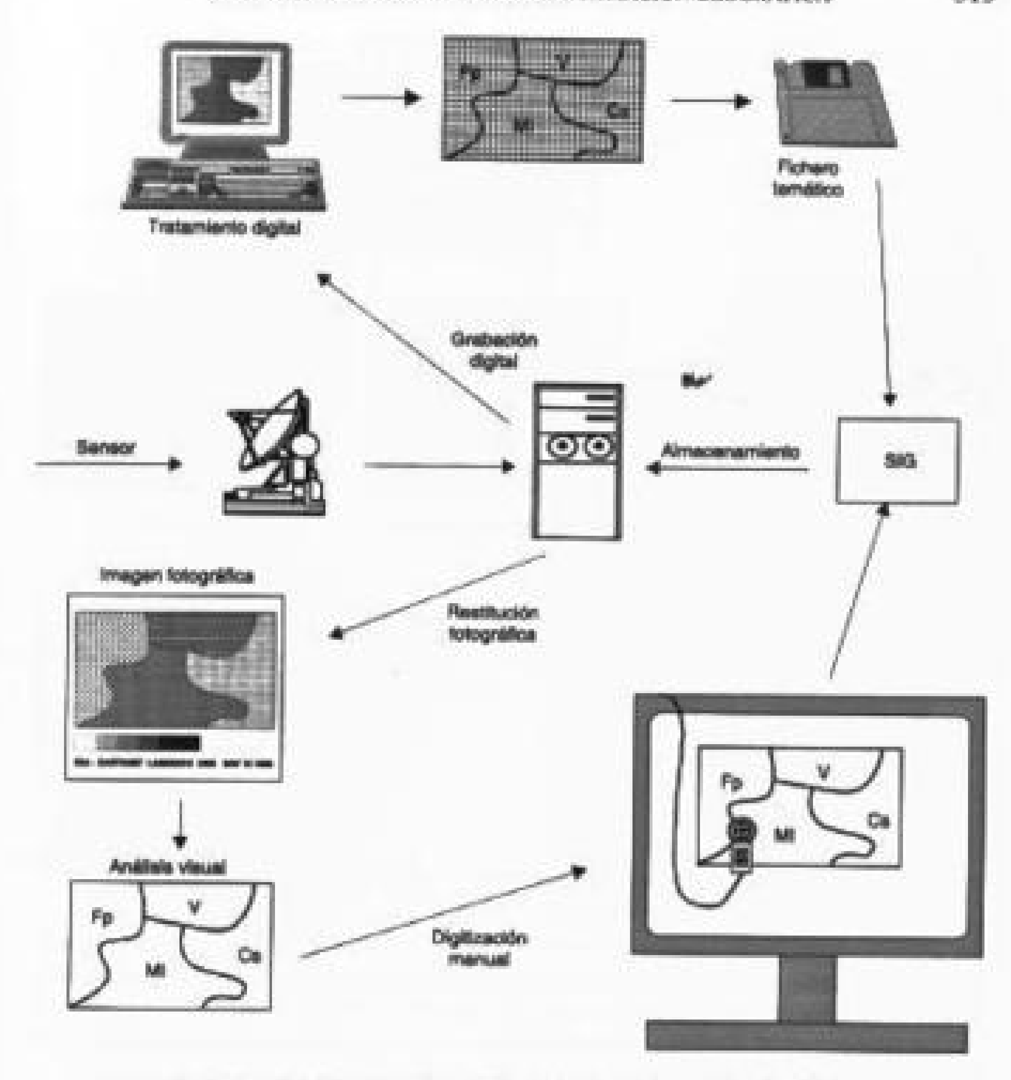


FIG. 9.4. *Modalidades de conexión entre la teledetección y los SIG.*

genes y el SIG cuando la interpretación se realizó digitalmente, ya que podemos obviar la digitización de los resultados. Ahí se presentan dos alternativas, según se trate de SIG ráster o vectoriales (fig. 9.5). En el primer caso podemos considerar al píxel como la unidad teselar de un SIG ráster, por lo que la conexión resulta mucho más directa. Si se trata de un SIG vectorial resultará preciso transformar el resultado a una lista de coordenadas, utilizando técnicas de vectorización, como luego comentaremos.

En cualquier caso, para integrar una imagen clasificada o una variable biofísica generada a partir de la interpretación de imágenes es preciso resolver dos problemas geométricos. Por un lado, que las características cartográficas de la imagen coincidan con las del SIG. Por otro, para el caso de los SIG ráster, que el tamaño del píxel y el origen de coordenadas sean el mismo. Para resolver ambos aspectos tendremos que apli-

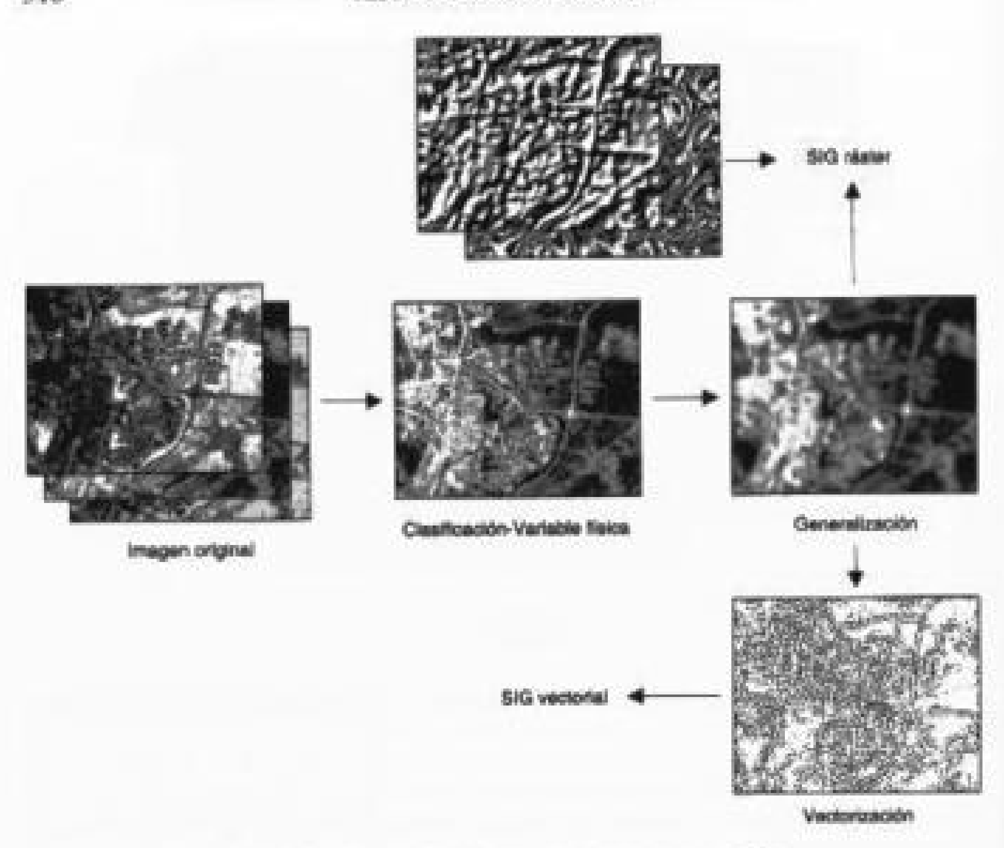


FIG. 9.5. *Integración de imágenes digitales en un SIG.*

car distintas operaciones según las características cartográficas de la imagen a introducir al SIG. En este sentido, puede ocurrir alguna de las siguientes situaciones (fig. 9.6): 1) que la imagen no esté geo-referenciada, 2) que ya lo esté, pero tenga una proyección y/o tamaño del píxel distintos a las del SIG, y 3) que tenga la misma proyección y tamaño del píxel, pero no el mismo origen de coordenadas.

En caso de que la imagen no esté geo-referenciada se utilizarán los procedimientos de corrección geométrica antes comentados (cap. 6, apdo. 6.3), utilizando como referencia la proyección cartográfica del SIG, lo que garantizará que la imagen de salida tenga sus mismas propiedades geométricas. En ese caso, sólo será necesario asegurar en la interpolación final que la ventana a corregir (coordenadas de las esquinas), así como el tamaño del píxel de salida, coinciden con los demás variables cartográficas almacenadas en el SIG. De otro modo, no podrán integrarse los resultados al SIG, puesto que la mayor parte de estos programas sólo pueden poner en relación ficheros que tengan el mismo número de filas y columnas.

En caso de que la imagen ya esté geo-referenciada, pero no a la base cartográfica del SIG (no coinciden proyección y/o elipsoide de referencia y/o datum), deberá realizarse una nueva corrección geométrica de la imagen, aunque en este caso sólo en su tercera fase (interpolación), ya que la transformación de un sistema de coordenadas a

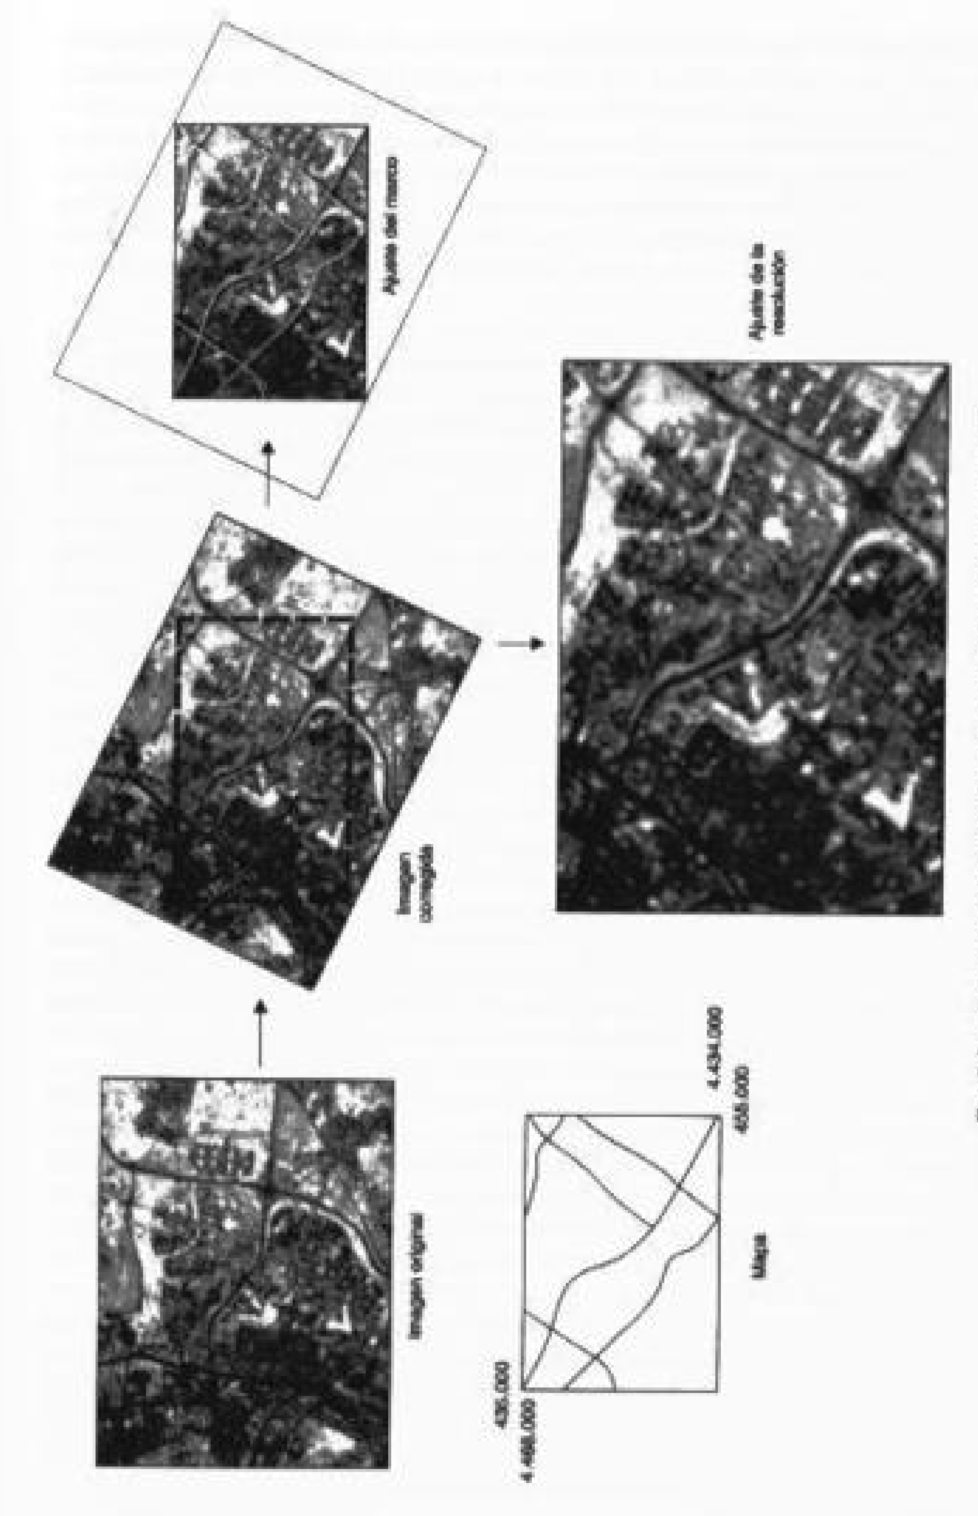


FIG. 9.6. *Aspectos geométricos en la integración de imágenes a un SIG.*

otro puede modelarse *a priori* (no necesitamos puntos de control para estimar la transformación, por tanto). La mayor parte de los programas de ADI cuentan con una amplia lista de proyecciones cartográficas definidas, por lo que pasar de una a otra resultará un proceso bastante automático, consistente en un remuestreo (por cualquiera de los procesos de trasvase de ND comentados en cap. 6, apdo. 6.3), de la proyección inicial a la deseada. El mismo hecho se daría cuando la imagen coincidiera cartográficamente con el SIG, pero el tamaño del píxel fuera distinto. También sería preciso, entonces, remuestrear la imagen, aunque lógicamente en ese caso no se modificaría la geometría de partida.

Finalmente, puede ocurrir que coincidan la proyección, elipsoide y tamaño de píxel entre la imagen y el SIG, pero no las coordenadas límite del marco geográfico que abarcan (esto es, las coordenadas de las esquinas). En ese caso, también es preciso realizar una transformación, aunque se limite a recortar o ampliar el marco de la imagen, para que el archivo de salida tenga el mismo número de filas y de columnas que el resto de las variables almacenadas en el SIG.[4]

En caso de trabajar con un SIG de tipo vectorial, los matices del ajuste geométrico son menos delicados, ya que no necesitamos considerar el tamaño del píxel, ni frecuentemente tampoco la ventana de coordenadas (la imagen puede abarcar una zona más grande o más pequeña que la incluida en el SIG). No obstante, sí es necesario que la proyección, elipsoide y datum coincidan. Posteriormente, es preciso abordar una conversión de estructura ráster a vectorial (vectorización), utilizando algoritmos de «adelgazamiento» de píxeles y reconstrucción automática de líneas. Estos programas suelen ser bastante automáticos, pero también pueden cometer notables errores, por lo que se recomienda una cierta supervisión por parte del intérprete, especialmente en los sectores de la imagen de mayor complejidad espacial (múltiples cruces). Para realizar eficazmente esa tarea resulta casi imprescindible suavizar previamente la imagen, eliminando píxeles con asignaciones aisladas del contexto. Lo habitual, con este propósito, es utilizar filtros modales (2.3.5), que resultan muy apropiados para imágenes clasificadas. En caso de que intentemos incorporar a un SIG una imagen correspondiente a una variable de intervalo (p. ej., temperatura), será más conveniente utilizar algoritmos de interpolación de líneas, frecuentemente utilizados para generar curvas de nivel en un MDE.

Un último aspecto que hace referencia a la integración entre la teledetección y los SIG lleva a considerar los mecanismos para combinar variables generadas en uno u otro contexto. Como ya comentamos más arriba, esta mezcla de fuentes puede considerarse una modalidad específica de las técnicas de fusión de datos (Gong, 1994). En este sentido se han propuesto diversas técnicas para integrar variables de distintas procedencia, como puede ser la Teoría de la Decisión (Gong, 1996), la Evaluación Multicriterio (Barredo, 1996), y las redes neuronales (Hewitson y Crane, 1994).

4. Para que esto sea posible es necesario que las coordenadas del área de referencia del SIG coincidan, en algún lugar de la malla, con las de la imagen. De lo contrario, será necesario optar por la opción anterior (remuestrear la imagen), ya que sólo pueden recortarse en la imagen píxeles enteros. Éste sería el caso si el origen del SIG fuera, por ejemplo, de 435000 y 4467000, mientras la imagen contara con un origen en 434925 y 4467025, con un tamaño de píxel de 50 m. Habría medio píxel de la imagen original en la nueva, lo que no es posible. Sí se podría recortar, en cambio, esa imagen si el píxel de salida tuviera un tamaño de 25 m.

Independientemente de los problemas que pueda traer consigo, la conexión de la teledetección espacial con un SIG es, a nuestro juicio, la conclusión más lógica del empleo de esta técnica. Brinda enormes posibilidades para la realización de estudios ambientales, evaluación de recursos, análisis de impactos, modelos de localización, etc. Con el apoyo de estos sistemas informáticos, el estudioso del medio ambiente podrá preocuparse más del análisis que de la obtención de la información. Será posible diseñar alternativas para un proyecto, estimar comportamientos futuros, simular efectos antes de que éstos sean irreparables, etc.

7. Ejemplos de conexión entre la teledetección y los SIG

Presentamos, como conclusión de este capítulo, dos ejemplos de las posibilidades que brinda la conexión entre estas tecnologías. El primero de ellos pretendía realizar una cartografía del riesgo de incendios, combinando distintas variables que resultan críticas para el inicio o la extensión del fuego (Chuvieco y Salas, 1996; Salas y Chuvieco, 1994). El área de estudio se situó sobre las primeras estribaciones de la sierra de Gredos, entre las provincias de Ávila y Toledo, que presenta altos índices de riesgo para incendios forestales. Incluye los municipios de la vertiente norte (el Tiemblo, Burgohondo, Navaluenga) y sur de la cordillera (Sotillo de la Adrada, Casillas, Casavieja, etc.).

El modelo de integración de las variables parte de un esquema diseñado por el Departamento de Protección contra incendios forestales de la Dirección General de Conservación de la Naturaleza (DGCN, antiguo ICONA) para determinar el peligro de incendios. Se basa en las condiciones meteorológicas, topografía local, vegetación y actividad humana (fig. 9.7). La capa de vegetación se obtuvo a partir de la clasificación digital de una imagen Landsat-TM, combinándola con información topográfica y con texturas derivadas de la banda roja. A partir de la información meteorológica puntual se generaron mapas de temperatura máxima y humedad relativa, empleando técnicas de interpolación-extrapolación, mediante métodos de regresión, utilizando como variable auxiliar el MDE. Finalmente, la capa de riesgo humano se obtuvo realizando un análisis de distancia a las principales vías de comunicación y campings-zonas de ocio (se establecieron «pasillos» de riesgo de 150 m a ambos lados de estos elementos), en la medida en que resultaban indicadores de la actividad recreativa sobre el territorio. Finalmente, las distintas variables se integraron en un índice sintético de riesgo, que consideraba la probabilidad de ignición, así como el riesgo asociado al comportamiento y a la actividad humana.

En este caso, la fórmula para obtener el mapa resultado implica una ponderación selectiva de los distintos factores de riesgo, pero podrían plantearse otros criterios, como la realización de cruces cualitativos entre mapas o el establecimiento de pesos mediante análisis de regresión local (Chuvieco *et al.*, 1999*a*). La cartografía resultante (fig. 9.8) puede constituir un instrumento eficaz de gestión, complementando los sistemas de alerta convencionales. Permite estratificar un área relativamente amplia en niveles de riesgo, localizados con alta precisión geográfica. De esta forma, podrían concentrarse los esfuerzos de prevención en estos sectores (planificar quemas controladas, limpiezas manuales o mecánicas del sotobosque, diseñar líneas cortafuegos, loca-

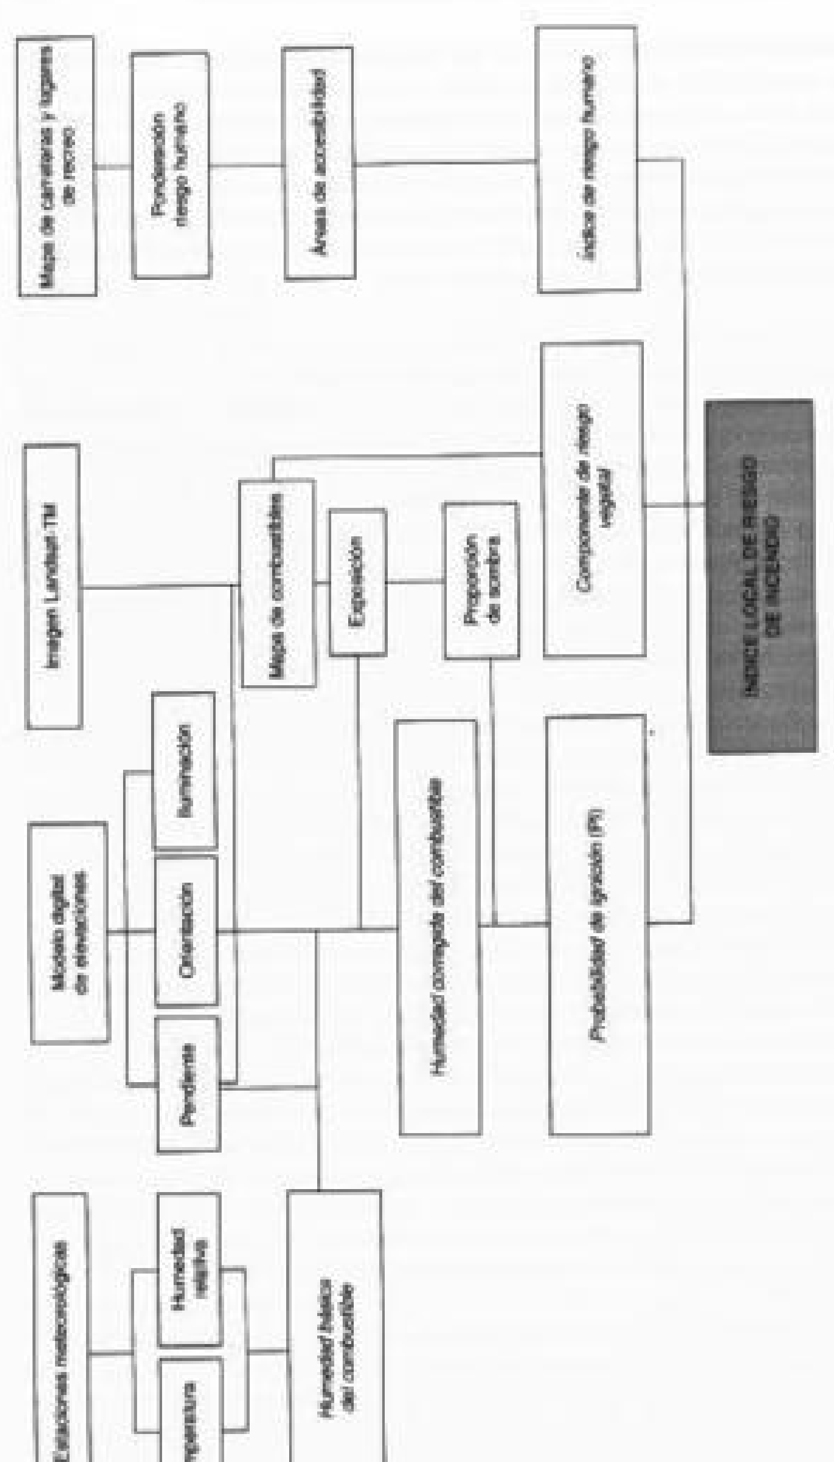


FIG. 9.7. *Esquema del sistema de riesgo de incendio de la DGCN.* (Salas y Chuvieco, 1994.)

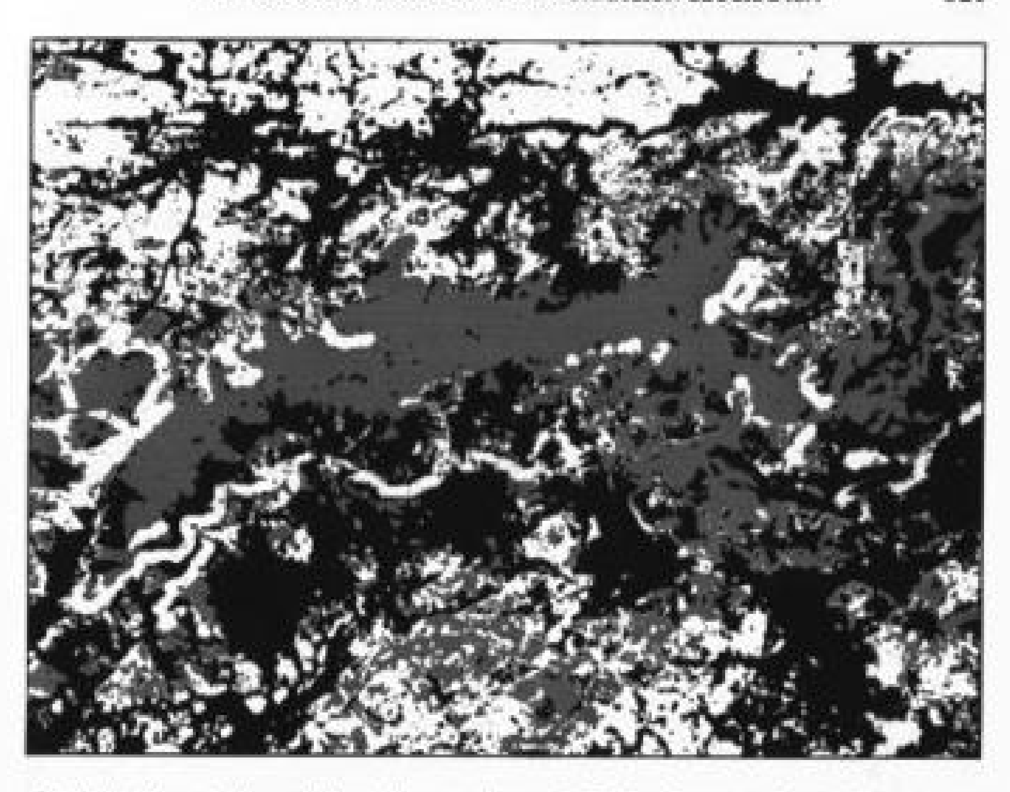


FIG. 9.8. *Mapa de riesgo de incendios para la zona de Gredos: los tonos claros indican mayor grado de riesgo.*

lizar torres de vigilancia, etc.), paliando la escasez de recursos. Además, puede también resultar un instrumento eficaz en el combate, para conocer la accesibilidad a los distintos sectores, planificar las cuadrillas móviles, o localizar medios de extinción.

El segundo ejemplo corresponde a un estudio sobre calidad ambiental de vida en ámbito urbano, tomando como ejemplo la ciudad venezolana de Maracay (fig. 9.9). En este caso se integraron diversas variables extraídas de teledetección y cartografía convencional, utilizando para ello las técnicas de evaluación multicriterio (Molina *et al.*, 1999). Las variables consideradas para este trabajo fueron la densidad de población y de viviendas (a partir de datos censales), la densidad del viario, la distancia a las industrias, al Lago de Valencia, el impacto visual de la industrias, la proximidad a vías de comunicación y la zona de inundación. Estas variables se generaron a partir de cartografía convencional, utilizando diversos análisis de proximidad. Junto a ellas, también se consideró el contraste térmico (a partir de interpolación de datos meteorológicos), la tipología residencial (mediante una clasificación de imágenes TM y SPOT), y la proporción de áreas verdes por barrio y proporción de áreas construidas por barrios (generadas ambas mediante el ALME a partir de las citadas imágenes).

Todas estas variables se integraron utilizando los resultados de una encuesta a expertos (método Delphi), que permitió generar un índice simple a partir del método de la sumatoria lineal ponderada, bastante común en las técnicas de evaluación multicri-

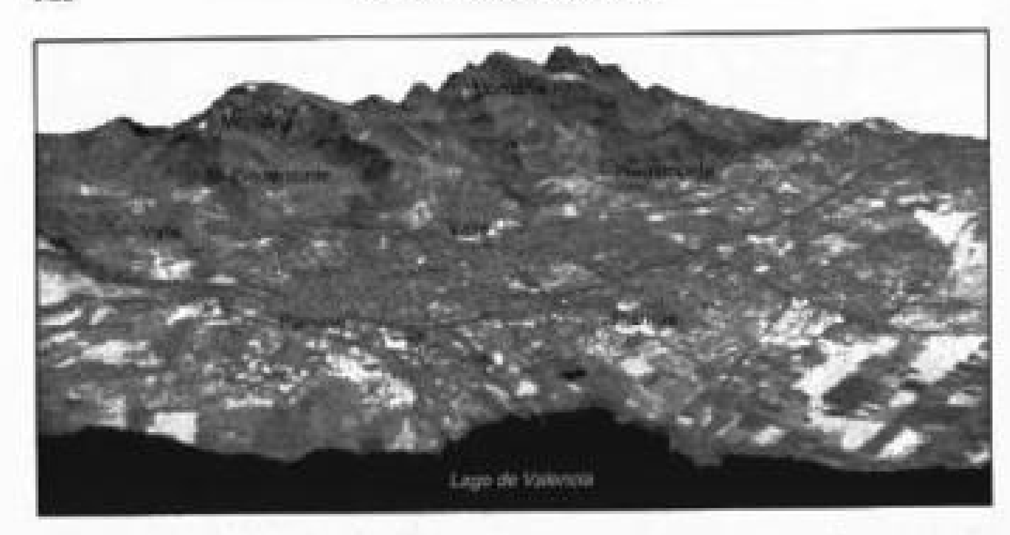


FIG. 9.9. *Vista tridimensional de la ciudad de Maracay (Venezuela).*

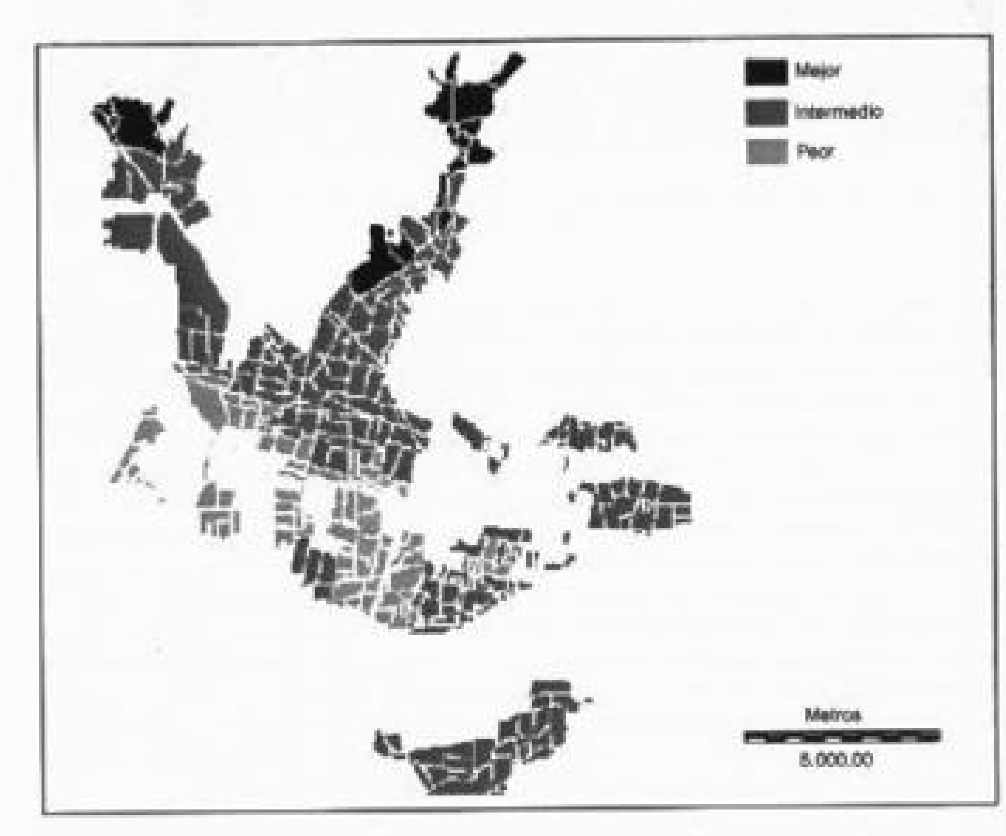


FIG. 9.10. *Resultados de la estratificación de los barrios de Maracay a partir de su calidad ambiental urbana.*

terio. Esto permitió obtener una visión global de la distribución de la calidad de vida en los distintos barrios de la ciudad (fig. 9.10), lo que puede mejorar las tareas de planificación urbana en la zona.

Existen otros múltiples ejemplos similares a éste en donde las imágenes de satélite se insertan en un flujo más global de análisis geográfico. Esperamos que este manual sea útil para que tales aplicaciones todavía se extiendan más, especialmente en los países en vías de desarrollo, en donde resulta tan necesario armonizar el crecimiento económico con la preservación del medio ambiente.

REFERENCIAS BIBLIOGRÁFICAS

Adams, J. B.; Sabol, D. E.; Kapos, V.; Almeida, R.; Roberts, D. A.; Smith, M. O. y Gillespie, A. R. (1995): «Classification of Multispectral Images Based on Fractions of Endmembers: Application to Land-Cover Change in the Brazilian Amazon», *Remote Sensing of Environment*, 52, pp. 137-154.

Adams, J. B.; Smith, M. O. y Johnson, P. E. (1986): «Spectral mixture modelling: a new analysis of rock and soil types at the Viking Lander I site», *Journal of Geophysical Research*, 91, pp. 8.098-8.112.

Adeniyi, P. O. (1985): «Digital analysis of multitemporal Landsat data for land use/land cover classification in a semi-arid area of Nigeria», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 1761-1774.

— (1987): «Using remotely sensed data for census surveys and population estimation in developing countries: examples from Nigeria», *Geocarto International*, 2, pp. 11-32.

Ahern, F. J.; Erdle, T.; Maclean, D. A. y Kneppeck, I. D. (1991): «A quantitative relationship between forest growth rates and Thematic Mapper reflectance measurements», *International Journal of Remote Sensing*, 12, pp. 387-400.

Ahern, F. J.; Goldammer, J. G. y Justice, C. O. (eds.) (2001): *Global and Regional Vegetation Fire Monitoring from Space: Planning a coordinated international effort*, The Haghe (Holanda), SPB Academic Publishing.

Aldakheel, Y. Y. y Danson, F. M. (1997): «Spectral reflectance of dehydrating leaves: measurements and modelling», *International Journal of Remote Sensing*, 18, pp. 3683-3690.

Alía, M.; Martín, C.; Ubanell, A. G. y Muñoz, L. (1976): «Determination by means of Landsat images of different geological structures in the central areas of the Iberian Plateau», en R. Núñez de las Cuevas (ed.), *Thematic Mapping, Land Use, Geological Structure and Water Resources in Central Spain*, Madrid, NASA Project 28.760, pp. 172-208.

Allan, T. D. (ed.) (1983): *Satellite Microwave Remote Sensing*, Nueva York, Ellis Howard Ltd.

Alonso, M.; Camarasa, A.; Chuvieco, E.; Cocero, D.; Kyun, I.; Martín, M. P. y Salas, F. J. (1996): «Estimating temporal dynamics of fuel moisture content of Mediterraneam species from NOAA-AVHRR data», *EARSEL Advances in Remote Sensing*, 4, pp. 9-24.

Anderson, J. R.; Hardy, E. E.; Roach, J. T. y Witmer, R. E. (1976): «A Land Use and Land Cover Classification System for Use with Remote Sensor Data», *U. S. Geological Survey*, Prof. Paper, Washington, D.C., p. 964.

Aplin, P.; Atkinson, P. y Curran, P. J. (1999): «Per-field classification of land use using the forthcoming very fine spatial resolution satellite sensors: problems and potential solutions», en P. M. Atkinson y N. J. Tate (eds.), *Advances in Remote Sensing and GIS analysis*, Chichester, John Wiley & Sons, pp. 219-239.

Arbiol, R.; Arozarena, A. y Villa, G. (1994): «Cartografía digital en áreas sin cobertura de ma-

pas en la cuenca del Orinoco en Venezuela, mediante imágenes de satélite, fotos aéreas infrarrojo y GPS», *Revista Española de Teledetección*, 3, pp. 58-59.

Aronoff, S. (1982): «The map accuracy report: A user's view», *Photogrammetric Engineering and Remote Sensing*, 48, pp. 1309-1312.

— (1989): *Geographic Information Systems: a management perspective*, Ottawa, WDL Publications.

Arozarena, A.; Calero, E.; Delgado, J. y Vivas, P. (1989): «Aplicaciones de las imágenes espaciales a la cartografía de base», en R. Núñez de las Cuevas y F. Fourneau (eds.), *Coloquio Hispano-Francés sobre Teledetección y Planificación Integrada del Territorio*, Madrid, I.G.N., pp. 215-223.

Asrar, G. (ed.) (1989): *Theory and Applications of Optical Remote Sensing*, Nueva York, Wiley.

Asrar, G.; Myneni R. M. y Kanemasu E. T. (1989): «Estimation of plant canopy attributes from spectral reflectance measurements», en G. Asrar (ed.), *Theory and Applications of Optical Remote Sensing*, Nueva York, Wiley, pp. 252-296.

Astaras, T. (1984): «Land complex classification of the Mula area, Murcia Province, Southeast Spain», *Geografiska annaler*, 66A, pp. 307-325.

Atkinson, P.; Cushnie, J. L.; Townshend, J. R. G. y Wilson, A. (1985): «Improving Thematic Mapper land cover classification using filtered data», *International Journal of Remote Sensing*, 6, pp. 955-961.

Au, K. N. (ed.) (1993): *Cities of the world as seen from space*, Hong Kong, Geocarto International Centre.

Bachmann, M. y Bendix, J. (1992): «An improved algorithm for NOAA-AVHRR image referencing», *International Journal of Remote Sensing*, 13, pp. 3205-3215.

Baker, J. C. (2001): «New users and established experts: bridging the knowledge gap in interpreting commercial satellite imagery», en J. C. Baker, K. M. O'Connell y R. A. Williamson (eds.), *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 533-557.

Baker, J. C.; Williamson, R. A. y O'Connell, K. M. (2001): «Introduction», en J. C. Baker, K. M. O'Connell y R. A. Williamson (eds.), *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 1-16.

Baltsavias, E. P. (1999): «Airborne laser scanning: existing systems and firms and other sources», *ISPRS Journal of Photogrammetry and Remote Sensing*, 54, pp. 164-198.

Bannari, A.; Morin, D.; Bonn, F. y Huete, A. R. (1995): «A review of vegetation indices», *Remote Sensing Reviews*, 13, pp. 95-120.

Baret, F. (1995): «Use of spectral reflectance variation to retrieve canopy biophysical characteristics», en F. M. Danson y S. E. Plummer (eds.), *Advances in Environmental Remote Sensing*, Chichester, John Wiley & Sons, pp. 33-51.

Baret, F. y Fourty, T. (1997): «Estimation of leaf water content and specific leaf wight from reflectance and transmitance measurements», *Agronomie*, 17, pp. 455-44.

Barnsley, M. J. y Hobson, P. (1997): «Teaching the principles of optical remote sensing using graphical tools developed in TCL/TK», *Remote Sensing Society Annual Conference*.

Barr, S. y Barnsley, M. J. (2000): «Reducing structural clutter in land cover classifications of high spatial resolution remotely-sensed images for urban land use mapping», *Computers and Geosciences*, 26, pp. 433-449.

Barredo, J. I. (1996): *Sistemas de Información Geográfica y Evaluación Multicriterio en la ordenación del territorio*, Madrid, RA-MA.

Barret, E. C. (1974): *Climatology from Satellites*, Londres, Methuen.

Barret, E. C. y Curtis, L. F. (1999*a*): *Introduction to Environmental Remote Sensing*, 4.ª edición, Cheltenham, Stanley Thornes Publishers Ltd.

— (1999*b*): «Calibration, evaluation and validation in remote sensing», en *Introduction to Environmental Remote Sensing*, Cheltenham, Stanley Thornes Publishers Ltd, pp. 117-134.

Barreto, M. M. (2000): «Las imágenes NOAA y los recursos pesqueros en el litoral peruano», *IX Simposio Latinoamericano de Percepción Remota*, Iguazú.

Bastarrika, A. (2000): «Desarrollo de rutinas de pre-procesamiento de imágenes AVHRR», *Proyecto fin de carrera*, Departamento de Geografía, Universidad de Alcalá.

Baudot, Y. (1990): «Integration of high-quality remote sensing images with low cost geographical information systems», *EGIS'90*, Utrecht, pp. 40-46.

Bauer, T. y Steinnocher, K. (2001): «Per-parcel land use classification in urban areas applying a rule-based technique», *GIS*, 6, pp. 24-27.

Beaven, P. J. (1988): «A very low-cost microcomputer-based image processor», en J. P. Muller (ed.), *Digital Image Processing in Remote Sensing*, Londres, Taylor & Francis, pp. 123-133.

Becker, F. y Choudhury, B. J. (1988): «Relative Sensitivity of Normalized Difference Vegetation Index (NDVI) and Microwave Polarization Difference Index (MPDI) for Vegetation and Desertification Monitoring», *Remote Sensing of Environment*, 24, pp. 297-311.

Belward, A. S. (1991): «Spectral Characteristics of vegetation, Soil and Water in the Visible, Near-Infrared and Middle-Infrared Wavelengths», en A. S. Belward y C. R. Valenzuela (eds.), *Remote Sensing and GIS for Resource Management in Developing Countries*, Dordrecht, Kluwer Academic Publishers, pp. 31-53.

Benediktsson, J. A.; Swain, P. H. y Ersoy, O. K. (1990): «Neural network approaches versus statistical methods in classification of multisource remote sensing data», *IEEE Transactions on Geoscience and Remote Sensing*, 28, pp. 540-552.

Benson, A. S. y Degloria, S. (1984): «Interpretation of Landsat-4 Thematic Mapper and Multispectral Scanner data for forest surveys», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 1281-1289.

Benson, B. J. y MacKenzie, M. D. (1995): «Effects of sensor spatial resolution on landscape structure parameters», *Landscape Ecology*, 10, pp. 113-120.

Berk, A.; Anderson, G. P.; Bernstein, L. S.; Acharya, P. K.; Dothe, H.; Matthew, M. W.; Adler-Golden, S. M.; Chetwynd, J. H.; Richtsmeier, S. C.; Pukall, B.; Allred, C. L.; Jeong, L. S. y Hoke, M. L. (1999): «MODTRAN4 Radiative Transfer Modeling for Atmospheric Correction», *SPIE Proceeding, Optical Spectroscopic Techniques and Instrumentation for Atmospheric and Space Research III*.

Bernstein, R. (1978): «Digital image processing of Earth observation sensor data», en R. Bernstein (ed.), *Digital Image Processing for Remote Sensing*, Nueva York, IEEE Press, pp. 55-72.

Berry, B. J. y Baker, A. M. (1968): «Geographic Sampling», en B. J. Berry y D. F. Marble (eds.), *Spatial Analysis*, Nueva Jersey, Englewood Cliffs, pp. 91-100.

Bhargava, D. S. y Mariam, D. W. (1990): «Spectral reflectance relationships to turbidity generated by different clay materials», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 225-229.

Biging, G.; Colby, D. R. y Congalton, R. G. (1998): «Sampling Systems for Change Detection Accuracy Assessment», en R. S. Luneta y C. D. Elvidge, *Remote Sensing Change Detection. Environmental Monitoring Methods and Applications*, Chelsea, MI, Ann Arbor Press, pp. 281-308.

Bischof, H.; Schneider, W. y Pinz, A. J. (1992): «Multispectral classification of Landsat images using neural networks», *IEEE Transactions on Geoscience and Remote Sensing*, 30, pp. 482-489.

Bishop, Y.; Fienberg, S. y Holland, P. (1975): *Discrete Multivariate Analysis: Theory and Practice*, Cambridge, MIT Press.

Blom, R. G. y Daily, M. (1982): «Radar image processing for rock-type discrimination», *IEEE Transactions on Geoscience Electronics*, GE20, pp. 343-351.

Boardman, J. B.; Kruse, F. A. y Green, R. O. (1995): «Mapping target signatures via partial unmixing of AVIRIS data», *Fifth Annual JPL Airborne Earth Science Workshop*, Pasadena, CA, NASA, Jet Propulsion Laboratory, pp. 23-26.

Booth, D. J. y Oldfield, R. B. (1989): «A comparison of classification algorithms in terms of speed and accuracy after the applications of a post-classification modal filter», *International Journal of Remote Sensing*, 10, pp. 1271-1276.

Bordes, P.; Brunel, P. y M. A. (1992): «Automatic adjustment of AVHRR navigation», *Journal of Atmospheric and Oceanic Technology*, 9, pp. 15-27.

Bosque, J. (1997): *Sistemas de Información Geográfica*, 2.ª Edición, Madrid, Rialp.

Bosque, J.; Chuvieco, E.; Navalpotro, P. y Sancho, J. (1991): «Factores en la dinámica de la ocupación del suelo (Comarca de los Montes, Castilla la Mancha, España)», *III Conferencia Latinoamericana sobre Sistemas de Información Geográfica*, Viña del Mar, pp. 355-362.

Bowman, W. D. (1989): «The relationship between leaf water status, gas exchange, and spectral reflectance in cotton leaves», *Remote Sensing of Environment*, 30, pp. 249-255.

Briggs, J. y Nellis, D. (1991): «Seasonal variation of heterogeneity in the tallgrass prairie: a quantitative measure using remote sensing», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 407-411.

Bronsveid, M. C. y Luderus, F. J. D. (1982): *Analysis of Multi-temporal Data for the Identification of Land Use and crops (Case Study on the Mérida Region in the Province of the Badajoz, SW Spain)*, Madrid, ITC-IBM Scientific Center.

Brookes, A. J. (1975): *Photo Reconnaissance: The Operational History*, Londres, Ian Allan.

Brown, J. F.; Loveland, T. R.; Merchant, J.; Reed, B. C. y Ohlen, D. O. (1993): «Using multi-source data in global land-cover characterization: concepts, requirements, and methods», *Photogrammetric Engineering and Remote Sensing*, 59, pp. 977-987.

Brown, J. K.; Booth, G. D. y Simmerman, D. G. (1989): «Seasonal Change in Live Fuel Moisture of Understory Plants in Western U.S.», Aspen, *10th Conference on Fire and Forest Meteorology*, Ottawa, Canadá, pp. 406-412.

Bruce, B. y Hornsby, J. K. (1987): «A Canadian perspective on the application of satellite remote sensing to regional geobotany», *Geocarto International*, 1, pp. 53-59.

Bruneau, M. y Gautier, B. (1981): «Cartographie diachronique de l'occupation du sol en milieu tropical densement people (Thailande)», *4eme Coll. Inter. du GDTA*, Toulouse, pp. 230-240.

Bruzzone, L. y Fernández-Prieto D. (2000): «An adaptive parcel-based technique for unsupervised change detection», *International Journal of Remote Sensing*, 21, pp. 817-822.

Bullard, R. K. y Dixon-Gough, R. W. (1985): *Britain from Space. An Atlas of Landsat Images*, Londres, Taylor & Francis Ltd.

Burgan, R. E.; Klaver, R. W. y Klaver, J. M. (1998): «Fuel models and fire potential from satellite and surface observations», *International Journal of Wildland Fire*, 8, pp. 159-170.

Burrough, P. A. y McDonell, R. A. (1998): *Principles of Geographical Information Systems*, Oxford, Oxford University Press.

Byrne, G. F.; Crapper, P. F. y Mayo, K. K. (1980): «Monitoring land-cover change by Principal Component analysis of multitemporal Landsat Data», *Remote Sensing of Environment*, 10, pp. 175-184.

Cachorro, V. E.; Durán, P.; Vergaz R. y Frutos, A. M. (2000): «Estudio de la influencia de los aerosoles sobre la reflectancia de los canales 1 y 2 del sensor AVHRR-NOAA y el NDVI», *Revista de Teledetección*, 13, pp. 13-26.

Caetano, M. y Oliveira, T. (1998): *The CNIG Digital Spectral Library*, Lisboa, CNIG.

Caetano, M. S.; Mertes, L. A. K. y Pereira, J. M. C. (1994): «Using Spectral Mixture Analysis for Fire Severity Mapping», *2nd Int. Conf. Forest Fire Research*, Coimbra, pp. 667-677.

Caetano, M. S.; Mertes, L.; Cadete, L. y Pereira, J. M. C. (1996): «Assessment of AVHRR data for characterising burned areas and post-fire vegetation recovery», *EARSeL Advances in Remote Sensing*, 4, pp. 124-134.

Calvet, J. y Pascual, R. (1987): «Estudio de alineaciones obtenidas a partir de imágenes radar del Seasat-SAR en el macizo del Montseny-Guilleries», *II Reunión Científica del Grupo de Trabajo en Teledetección*, pp. 41-47.

Camarasa, A. M.; Salas, J. y Chuvieco, E. (2001): «Información geográfica y riesgos naturales», *El Campo de las Ciencias y las Artes (Servicio de Estudios del BBVA)*, 138, pp. 103-136.

Campbell, J. B. (1981): «Spatial correlation effects upon accuracy of supervised classification of land cover», *Photogrammetric Engineering and Remote Sensing*, 47, pp. 355-363.

— (1996): *Introduction to Remote Sensing*, 2.ª ed., Nueva York, The Guilford Press.

Cañón, M. L. (2000): «Aplicación de la teledetección para la determinación de indicadores de áreas con mayor probabilidad de pesca en el sector noreste del Caribe Colombiano», *IX Simposio Latinoamericano de Percepción Remota*, Iguazú.

Carleton, A. M. (1991): *Satellite Remote Sensing in Climatology*, Londres, Belhaven Press.

Carper, W. J.; Lillesand T. M. y Kiefer, R. W. (1990): «The use of Intensity-Hue-Saturation transformation for merging SPOT pancromatic and multispectral image data», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 459-467.

Carter, G. A. (1991): «Primary and secondary effects of water content on the spectral reflectance of leaves», *American Journal of Botany*, 78, pp. 916-924.

Carter, P. y Stow, B. (1979): «Clean-up of digital thematic maps of urban growth extracted from Landsat imagery», en J. A. Allan y R. Harris, *Remote Sensing and National Mapping*, Reading, Remote Sensing Society, pp 27-40.

Carvacho, L. (1998): «Evaluación de la estimación de grandes incendios forestales en la cuenca mediterránea europea por redes neuronales y regresión logística», *Serie Geográfica*, 7, pp. 73-85.

Casas, J. M. y Chuvieco, E. (1987): «Análisis visual de imágenes "Thematic Mapper" para el estudio urbano. El caso de la ciudad de Madrid», *Anales de Geografía de la Universidad Complutense*, 7, pp. 401-415.

Caselles, V. (1987): «La utilidad del semivariograma en estudios de teledetección», *II Reunión Nacional del Grupo de Trabajo en Teledetección*, Valencia, pp. 121-129.

Caselles, V. y López, M. J. (1989): «An alternative simple approach to estimate atmospheric correction in multitemporal studies», *International Journal of Remote Sensing*, 10, pp. 1127-1134.

Caselles, V. y Sobrino, J. A. (1989): «Determination of frosts in orange groves from NOAA-9 AVHRR Data», *Remote Sensing of Environment*, 29, pp. 135-146.

Caselles, V.; Sobrino J. A. y F. Becker (1988): «Determination of the effective emissivity and temperature under vertical observation of a citrus orchard. Application to frost nowcasting», *International Journal of Remote Sensing*, 9, pp. 715-727.

Caselles, V.; Coll, C.; Rubio, E.; Sospedra F. y Valor E. (1995): «La medida de la temperatura y de la emisividad desde satélites: estado actual y perspectivas futuras», *VI Reunión Científica de la Asociación Española de Teledetección*, Valladolid, pp. 487-492.

Castel, T.; Martínez, J. M.; Beaudoin, A.; Wegmuller, U. y Strozzi T. (2000): «ERS INSAR data for remote sensing hilly forested areas», *Remote Sensing of Environment*, 73, pp. 73-86.

Castleman, K. E. (1978): «The Gray Level Histogram», en *Digital Image Processing*, Englewood Cliffs, Prentice Hall, pp. 68-84.

Castro, R. y Chuvieco E. (1995): «Clasificación digital de combustibles forestales a partir de imágenes de alta resolución y modelos digitales del terreno», *Boletín de la SELPER*, 10, pp. 8-15.
— (1998): «Modeling Forest Fire Danger From Geographic Information Systems», *Geocarto International*, 13, pp. 15-23.
Cebrián, J. A. (1988): «Sistemas de Información Geográfica», en J. Bosque (ed.), *Aplicaciones de la Informática a la Geografía y Ciencias Sociales*, Madrid, Síntesis, pp. 125-140.
Ceccato, P.; Flasse, S.; Tarantola, S.; Jacquemoud S. y Grégoire J. M. (2001): «Detecting vegetation leaf water content using reflectance in the optical domain», *Remote Sensing of Environment*, 77, pp. 22-33.
Chang, A. T. C.; Fuster J. L. y Hall D. K. (1990): «Satellite Sensor Estimates of Northern Hemisphere Snow Volume», *International Journal of Remote Sensing*, 11, pp. 167-171.
Chapelle, E. W.; Wood, F. W.; McMurtrey J. E. y Newcomb, W. W. (1984): «Laser-induced fluorescence of green plants. 1: A technique for the remote detection of plant stress and species differentiation», *Applied Optics*, 23, p. 134.
Chavez, P. S. (1975): «Atmospheric, solar, and MTF corrections for ERTS digital imagery», *Proceedings of the American Society of Photogrammetry*, Falls Church, VA.
— (1988): «An improved dark-object subtraction technique for atmospheric scattering correction of multispectral data», *Remote Sensing of Environment*, 24, pp. 459-479.
— (1996): «Image-based atmospheric corrections. Revisited and improved», *Photogrammetric Engineering and Remote Sensing*, 62, pp. 1025-1036.
Chavez, P. S. y Kwarteng, A. Y. (1989): «Extracting spectral contrast in Landsat Thematic Mapper image data using selective principal component analysis», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 339-348.
Chavez, P. S.; Sides, S. C. y Anderson, J. A. (1991): «Comparison of three different methods to merge multiresolution and multispectral data: Landsat TM and SPOT Panchromatic», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 295-303.
Chen, H. S. (1985): *Space Remote Sensing Systems. An Introduction*, Orlando, Academic Press.
Chen, Z.; Elvidge, C. D. y Groenveld, D. P. (1998): «Monitoring of seasonal dynamics of arid land vegetation using AVIRIS data», *Remote Sensing of Environment*, 65, pp. 255-266.
Chevrel, M.; Courtois, M. y Weill, G. (1981): «The SPOT satellite remote sensing mission», *Photogrammetric Engineering & Remote Sensing*, 47, pp. 1163-1171.
Chica, M. (1988): *Análisis Geoestadístico en el Estudio de la Explotación de los Recursos Minerales*, Granada, Universidad de Granada.
Chicharro, E. (1978): «Cartografía del uso del suelo sobre datos del Landsat», *Las Ciencias*, 43, pp. 127-131.
Chicharro, E. y Martínez, J. (1992): «El análisis visual de imágenes espaciales en la enseñanza de la Geografía», *Serie Geográfica*, 2, pp. 65-80.
Chladil, M. A. y Nunez, M. (1995): «Assessing grassland moisture and biomass in Tasmania. The application of remote sensing and empirical models for a cloudy environment», *International Journal of Wildland Fire*, 5, pp. 165-171.
Choudhury, B. J. (1997): «Global pattern of potential evaporation calculated from the Penman-Monteith equation using satellite and assimilated data», *Remote Sensing of Environment*, 61, pp. 64-81.
Choudhury, B. J. y Nicholson, S. E. (1992): «Synergistic use of multispectral satellite data for monitoring arid lands», en P. M. Mather, *TERRA-1: Understanding the Terrestrial Environment*, Londres, Taylor and Francis, pp. 67-76.
Choudhury, B. J.; Kerr, Y. H.; Njoku E. G. y Pampaloni, P. (eds.) (1994): *Passive Microwave Remote Sensing of Land-Atmosphere Interactions*, Utrecht, VSP BV.

Chuvieco, E. (1985*a*): «Análisis espectral, cartografía e inventario de tipos de ocupación a partir de imágenes Thematic Mapper», *Geographica*, 27, pp. 117-129.
— (1985*b*): «Aportaciones de la teledetección espacial a la cartografía de ocupación del suelo», *Anales de Geografía de la Universidad Complutense*, 5, pp. 29-48.
— (1986): *Análisis visual multiestacional de la ocupación del suelo en Madrid y Guadalajara: propuesta de cartografía a partir de imágenes espaciales*, Madrid, Instituto de Economía y Geografía Aplicada.
— (1992): «Teledetección, S.I.G. y Cambio Global», *Geographicalia*, 29, pp. 33-55.
— (1998): «El factor temporal en teledetección: evolución fenológica y análisis de cambios», *Revista Española de Teledetección*, 10, pp. 39-48.
— (1999*a*): «Measuring changes in landscape pattern from satellite images: short-term effects of fire on spatial diversity», *International Journal of Remote Sensing*, 20, pp. 2331-2347.
— (ed.) (1999*b*): *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlín, Springer-Verlag.
Chuvieco, E. y Congalton, R. G. (1988): «Using cluster analysis to improve the selection of training statistics in classifying remotely sensed data», *Photogrammetric Engineering & Remote Sensing*, 54, pp. 1275-1281.
Chuvieco, E. y Martín, M. P. (1994): «Global fire mapping and fire danger estimation using AVHRR images», *Photogrammetric Engineering and Remote Sensing*, 60, pp. 563-570.
— (1999): *Performance Assessment in the Fire Post-fire Phase. Final Report*, Alcalá de Henares, Department of Geography, FOQ-132-CT-05-1a.
Chuvieco, E. y Martínez Vega, J. (1990): «Visual Versus Digital Analysis for Vegetation Mapping: Some Examples on Central Spain», *Geocarto International*, 3, pp. 21-29.
Chuvieco, E. y Salas, F. J. (1996): «Mapping the spatial distribution of forest fire danger using GIS», *International Journal of Geographical Information Systems*, 10, pp. 333-345.
Chuvieco, E. y Sancho, J. (1986): «Tratamiento visual y digital de las imágenes espaciales: aplicaciones docentes», *Didáctica Geográfica*, 14, pp. 17-28.
Chuvieco, E.; Salas, F. J.; Carvacho, L. y Rodríguez-Silva, F. (1999*a*): «Integrated fire risk mapping», en E. Chuvieco (ed.), *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlín, Springer-Verlag, pp. 61-84.
Chuvieco, E.; Aguado, I.; Cocero D. y Riaño D. (2002*a*): «Design of an Empirical Index to Estimate Fuel Moisture Content from NOAA-AVHRR Analysis In Forest Fire Danger Studies», *International Journal of Remote Sensing*, 24, pp. 1621-1637.
Chuvieco, E.; Riaño, D.; Aguado I. y Cocero D. (2002*b*): «Estimation of fuel moisture content from multitemporal analysis of Landsat Thematic Mapper reflectance data: application in fire danger assessment», *International Journal of Remote Sensing*, 23, pp. 2145-2162.
Chuvieco, E.; Deshayes, M.; Stach, N.; Cocero, D. y Riaño, D. (1999*b*): «Short-term fire risk: foliage moisture content estimation from satellite data», en E. Chuvieco (ed.), *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlín, Springer-Verlag, pp. 17-38.
Chuvieco, E.; Salas, F. J.; Aguado, I.; Cocero, D. y Riaño, D. (2001): «Estimación del estado hídrico de la vegetación a partir de sensores de alta y baja resolución», *GeoFocus* (artículos), pp. 1-16.
Cibula, W. G.; Zetka, E. F. y R. D. L. (1992): «Response of Thematic Mapper bands to plant water stress», *International Journal Remote Sensing*, 13, pp. 1869-1880.
Cicone, R. y Metzler, M. D. (1984): «Comparison of Landsat MSS, Nimbus-7 CZCS, and NOAA-7 AVHRR features for land use analysis», *Remote Sensing of Environment*, 14, pp. 257-265.
Cihlar, J.; Manak, D. y Voisin, N. (1994): «AVHRR bidirectional reflectance effects and compositing», *Remote Sensing of Environment*, 48, pp. 77-88.
Cihlar, J.; St. Laurent, L. y Dyer, J. A. (1991): «Relation between the Normalized Differen-

ce Vegetation Index and ecological variables», *Remote Sensing of Environment*, 35, pp. 279-298.

Cihlar, J.; Xiao, Q.; Chen, J.; Beaubien, J.; Fung, K. y Latifovic, R. (1998): «Classification by progressive generalization: a new automated methodology for remote sensing multichanel data», *International Journal of Remote Sensing*, 19, pp. 2685-2704.

Civco, D. L. (1989): «Topographic Normalization of Landsat Thematic Mapper Digital Imagery», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 1303-1309.

— (1993): «Artificial neural networks for land-cover classification and mapping», *International Journal of Geographical Information Systems*, 7, pp. 173-186.

Clark, C. y Cañas, A. (1995): «Spectral identification by artificial neural network and genetic algorithm», *International Journal of Remote Sensing*, 16, pp. 2256-2272.

Clark, R. N.; Swayze, G. A.; Gallagher, A. J.; King, T. V. V. y Calvin, W. M. (1993): «The U.S. Geological Survey, Digital Spectral Library: Version 1: 0.2 to 3.0 microns», *U.S. Geological Survey Open File Report*, pp. 93-592.

Cliff, A. D. y Ord, J. K. (1973): *Spatial Autocorrelation*, Londres, Pion.

Cocero, D.; Riaño, D. y Chuvieco, E. (2000): «Estimación de la humedad de la vegetación de diferentes especies mediterráneas mediante distintos sensores de teledeteccion», *Tecnologías Geográficas para el Desarrollo Sostenible*, en I. Aguado y M. Gómez (eds.), Alcalá de Henares, Universidad de Alcalá, Departamento de Geografía, pp. 200-221.

Cohen, W. B. (1991): «Response of vegetation indices to changes in three measures of leaf water stress», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 195-202.

Cohen, W. B. y Spies, T. A. (1992): «Estimating structural attributes of Douglas-fir / Western Hemlock forest stands from Landsat and SPOT imagery», *Remote Sensing of Environment*, 41, pp. 1-17.

Cohen, W. B.; Spies, T. A. y Bradshaw, G. A. (1990): «Semivariograms of digital imagery for analysis of conifer canopy structure», *Remote Sensing of Environment*, 34, pp. 167-178.

Cohen, W. B.; Spies, T. A. y Fiorella, M. (1995): «Estimating the Age and Structure of Forests in a Multi-Ownership Landscape of Western Oregon», USA, *International Journal of Remote Sensing*, 16, pp. 721-746.

Colby, J. D. (1991): «Topographic normalization in rugged terrain», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 531-537.

Coleman, A. (1968): «Land Use Survey Handbook», *Isle of Thanet*, Geographical Association.

Coll, C.; Caselles, V.; Sobrino, J. A. y Valor, E. (1994): «On the atmospheric dependence of the split winclow equation for land surface temperature», *International Journal of Remote Sensing*, 15, pp. 105-122.

Collado, A. (1998): *Cobertura del suelo y desertificación en el Centro-Sur de la provincia de San Luis, Argentina. Evaluación multitemporal mediante técnicas de teledetección*, tesis doctoral, Departamento de Geografía, Universidad de Alcalá.

Colwell, J. E. (1974): «Vegetation canopy reflectance», *Remote Sensing of Environment*, 3, pp. 175-183.

Colwell, R. N. (ed.) (1983): *Manual of Remote Sensing. Second Edition*, Falls Church, Virginia, American Society of Photogrammetry.

Comas, D. y Ruiz, E. (1993): *Fundamentos de los Sistemas de Información Geográfica*, Barcelona, Ariel.

Conese, C.; Gilabert, M. A.; Maselli, F. y Bottai, L. (1993): «Topographic normalization of TM scenes through the use of an atmospheric correction method and digital terrain models», *Photogrammetric Engineering and Remote Sensing*, 59, pp. 1745-1753.

Congalton, R. B. (1984): «A comparison of five sampling schemes used in assessing the accuracy of land cover/land use maps derived from remotely sensed data», *Ph. D. Dissertation*, Virginia Polytechnic Institute.

Congalton, R. G. (1988*a*): «Using spatial autocorrelation analysis to explore the errors in maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 54, pp. 587-592.

— (1988*b*): «A comparison of sampling schemes used in generating error matrices for assessing the accuracy of maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 54, pp. 593-600.

— (1991): «A review of assessing the accuracy of classifications of remotely sensed data», *Remote Sensing of Environment*, 37, pp. 35-46.

Congalton, R. G. y Green, K. (1999): *Assessing the Accuracy of Remotely Sensed Data: Principles and Applications*, Boca Raton, Lewis Publishers.

Congalton, R. G.; Green, K. y Teply, J. (1993*b*): «Mapping old growth forests on National forest and park lands in the Pacific Northwest from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 59, pp. 529-535.

Congalton, R. G.; Stenback J. M. y Barret, R. H. (1993*a*): «Mapping deer habitat suitability using remote sensing and Geographic Information Systems», *Geocarto International*, 8, pp. 23-33.

Conway, E. D. (1997): *An Introduction to Satellite Image Interpretation*, Baltimore, Johns Hopkins University Press.

Coppin, P. R. y Bauer, M. E. (1994): «Processing of multitemporal Landsat TM imagery to optimize extraction of forest cover change features», *IEEE Transactions on Geoscience and Remote Sensing*, 32, pp. 918-927.

Coppock, J. T. y Rhind, D. W. (1991): «The History of GIS», en D. J. Maguire; M. F. Goodchild y D. W. Rhind (eds.), *Geographical Information Systems*, pp. 21-43.

Cosentino, M. J.; Woodcock, E. C. y Franklin, J. (1981): «Scene Analysis for Wildland Fire-Fuel Characteristics in a Mediterranean Climate», *15th International Symposium on Remote Sensing of Environment*, Ann Arbor, MI, pp. 635-646.

Couzy, A. (1981): *La Télédétection*, París, Presses Universitaires de France.

Cracknell, A. P. (1997): *The Advanced Very High Resolution Radiometer (AVHRR)*, Londres, Taylor & Francis.

Cracknell, A. P. y Hayes, L. W. B. (1991): *Introduction to Remote Sensing*, Londres, Taylor and Francis.

Crapper, P. F. y Hynson, K. C. (1983): «Change detection using Landsat photographic imagery», *Remote Sensing of Environment*, 13, pp. 291-300.

Crist, E. P. y Cicone, R. C. (1984*a*): «Application of the tasseled cap concept to simulated Thematic Mapper data», *Photogrammetric Engineering of Remote Sensing*, 50, pp. 343-352.

— (1984*b*): «A physically-based transformation of Thematic Mapper data the TM tasseled cap», *IEEE Transactions on Geoscience and Remote Sensing*, GE22, pp. 256-263.

Curran, P. (1980): «Remote Sensing systems for monitoring crops and vegetation», *Progress in Physical Geography*, 4, pp. 315-341.

Curran, P. J. (1981): «Multispectral remote sensing of vegetation amount», *Progress in Physical Geography*, 5, pp. 315-341.

— (1985): *Principles of Remote Sensing*, Londres, Longman.

— (1989): «Remote Sensing of Foliar Chemistry», *Remote Sensing of Environment*, 30, pp. 271-278.

Curran, P. J. y Foody G. M. (1994*a*): «Environmental Issues at Regional to Global Seales», en G. M. Foody y P. J. Curran (eds.), *Enviromental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons, pp. 1-7.

— (1994*b*): «The Use of Remote Sensing to Characterise the Regenerative States of Tropical Forests», *Environmental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons, pp. 44-83.

Curran, P. J. y Kupiec, J. A. (1995): «Imaging spectrometry: a new tool for ecology», en F. M. Danson y S. E. Plummer (eds.), *Advances in Environmental Remote Sensing*, Chichester, John Wiley & Sons, pp. 71-88.

Curran, P. J.; Foody, G. M.; Kondratyev, K. Y.; Kozoderov, W. y Fedchenko, P. P. (1990): *Remote Sensing of Soils and Vegetation in the USSR*, Londres, Taylor and Francis.

Cushnie, J. L. (1987): «The interactive effect of spatial resolution and degree of internal variability within land-cover types on classification accuracies», *International Journal of Remote Sensing*, 8, pp. 15-29.

Cushnie, J. L. y Atkinson, P. (1985): «The effect of spatial filtering on scene noise and boundary detail in Thematic Mapper imagery», *Photogrammetric Engineering and Remote Sensing*, 51, p. 1483.

Dai, X. y Khorram, S. (1998): «The effects of image misregistration on the accuracy of remotely sensed change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 36, pp. 1566-1577.

Danjoy, W. A. y Sadowski, F. G. (1978): «Use of Landsat in the study of forest classification in the tropical jungle», *12th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor, pp. 947-951.

Danson, F. M. (1998): «Factors controlling vegetation canopy reflectance: a teaching model», *Photogrammetric Engineering and Remote Sensing*, 64, pp. 809-812.

Danson, F. M. y Plummer, S. E. (eds.) (1995): *Advances in Environmental Remote Sensing*, Chichester, John Wiley & Sons.

Danson, F. M.; Plummer, S. E. y Briggs, S. A. (1995): «Remote Sensing and the information extraction problem», en F. M. Danson y S. E. Plummer (eds.), *Advances in Environmental Remote Sensing*, Chichester, John Wiley & Sons, pp. 171-177.

Davis, F. W. y Simonett, D. S. (1991): «GIS and Remote Sensing», en D. Maguire, M. F. Goodchild y D. W. Rhind (eds.), *Geographical Information Systems*, Londres, Longman, pp. 191-213.

Davison, G. J. (1984): «Ground control pointing and geometric transformation of satellite imagery», *Remote Sensing Workshop on Terrestrial Positioning and Geometric Correction of Imagery*, Nottingham, Department of Geography, University of Nottingham, pp. 45-59.

Deane, G. C. (1980): «Preliminary evaluation of Seasat-1 SAR data for land use mapping», *Geographical Journal*, 146, pp. 408-418.

DeFries, R. S. y Townshend, J. R. G. (1994): «Global Land-Cover: Comparison of Ground-Based Data Sets to classifications with AVHRR Data», en G. M. Foody y P. J. Curran, *Environmental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons, pp. 84-110.

Delbaere, B. y Gulinck, H. (1995): «A review of landscape ecological research with specific interest to landscape ecological mapping», en B. Delbaere y H. Gulinck (eds.), *Remote Sensing in landscape ecological mapping*, Luxembourg, Office for Official Publications of the European Communities, pp. 3-28.

D'Errico, M.; Mocha, A. y Vetrella, S. (1995): «High-frequency observation of Natural disasters by SAR interferometry», *Photogrammetric Engineering and Remote Sensing*, 61, pp. 891-898.

Desbois, N.; Deshayes, M. y Beudoin, A. (1997*a*): «Protocol for fuel moisture content measurements», en E. Chuvieco (ed.), *A review of remote sensing methods for the study of large wildland fires*, Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá, pp. 61-72.

Desbois, N.; Pereira, J. M. C.; Beuadoin, A.; Chuvieco, E. y Vidal, A. (1997*b*): «Short term fire risk mapping using remote sensing», en E. Chuvieco (ed.), *A review of remote sensing methods for the study of large wildland fires*, Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá, pp. 29-60.

Dietrich, D. L. y Lachowski, H. M. (1978): «Identification and delineation of urbanized areas using Landsat data», *12th Inter. Symp. on Remote Sensing of Environment*, Ann Arbor, pp. 1083-1090.

Díez de Arribas, J. M. y Nicolás, E. (2001): «Software de corrección geométrica automática de imágenes NOAA», *Proyecto Fin de Carrera*, Departamento de Geografía, Univerdad de Alcalá.

Dillworth, M. E.; Whistler, J. L. y Merchant, J. W. (1994): «Measuring landscape structure using geographic and geometric windows», *Photogrammetric Engineering and Remote Sensing*, 60, pp. 1215-1224.

Diner, D. J.; Asner, G. P.; Davies, R.; Knyazikhin, Y.; Muller, J. P.; Nolin, A. W.; Pinty, B.; Schaaf, C. y Stroeve, J. (1999): «New Directions in Earth Observing: Scientific Applications of Multiangle Remote Sensing», *Bulletin of the American Meteorological Society*, 80, pp. 2209-2228.

Dobson, M. C. (2000): «Forest Information from Synthetic Aperture Radar», *Journal of Forestry*, 98, pp. 41-43.

Dozier, J. (1989): «Spectral Signature of Alpine Snow Cover from Landsat Thematic Mapper», *Remote Sensing of Enviroment*, 28, pp. 9-22.

Dozier, J. y Strahler, A. H. (1983): «Ground Investigations in Support of Remote Sensing», en R. N. Colwell (ed.), *Manual of Remote Sensing*, Falls Church, American Society of Photogrammetry, pp. 959-986.

Drake, J. B. y Weishampel, J. F. (2000): «Multifractal analysis of canopy height measures in a longleaf pine savanna», *Forest Ecology and Management*, 128, pp. 121-127.

Drury, S. A. (1998): *Images of the Earth. A guide to Remote Sensing*, Oxford, Oxford University Press.

Dubayah, R. O. y Drake, J. B. (2000): «Lidar Remote Sensing of Forestry», *Journal of Forestry*, 98, pp. 44-46.

Duda, R. D. y Hart, P. E. (1973): *Pattern Classification and Scene Analysis*, Nueva York, John Wiley & Sons.

Duguay, C. R. y LeDrew, E. F. (1992): «Estimating surface reflectance and albedo from Landsat-5 TM over rugged terrain», *Photogrammetric Engineering and Remote Sensing*, 58, pp. 551-558.

Dymond, J. R.; Shepherd, J. D. y Qi, J. (2001): «A simply physical model of vegetation reflectance for standardising optical satellite imagery», *Remote Sensing of Environment*, 77, pp. 230-239.

Eastman, J. R.; McKendry, J. y Fulk, M. (1994): *UNITAR Explorations in GIS Technology, vol. 1: Change and Time Series Analysis*, Geneve, Switzerland.

Eastman, R. y Fulk, M. (1993): «Long sequence time series evaluation using standarized principal components», *Photogrammetric Engineering and Remote Sensing*, 59, 1307-1312.

Eastwood, J. A.; Plummer, B. K. y Wyatt, B. K. (2000): «The potential of SPOT-Vegetation data for fire scar detection in boreal forests», *International Journal of Remote Sensing*, 19, pp. 3681-3687.

Ehleringer, J. R. y Field, C. B. (eds.) (1993): *Scaling Physiological Processes. Leaf to Globe*, San Diego, Academic Press.

Ehrlich, D.; Estes, J. E. y Sing, A. (1994): «Applications of NOAA-AVHRR 1 Km. data for environmental monitoring», *International Journal of Remote Sensing*, 15, pp. 145-161.

Elachi, C. (1982): «Radar images of the Earth from space», *Scientific American*, 247, pp. 46-53.

— (1987): *Introduction to the Physics and Techniques of Remote Sensing*, Nueva York, John Wiley & Sons.

Elvidge, C. D. (2001): «DMSP-OLS estimation of tropical forest area impacted by surface fi-

res in Roraima», Brazil, 1995 versus 1998», *International Journal of Remote Sensing*, 22, pp. 2.661-2.673.

Elvidge, C. D. y Portigal, F. P. (1990): «Change detection in vegetation using AVIRIS data». *SPIE Imaging Spectroscopy of the terrestrial environment*, Orlando, FL., pp. 178-189.

Elvidge, C. D.; Baugh, K. B.; Hobson, V. R.; Kihn, E.; Kroehl, H. W.; Davis, E. R. y Cocero, D. (1997): «Satellite inventory of human settlements using nocturnal radiation emissions: a contribution for the global toolchest», *Global Change Biology*, 3, pp. 387-395.

Emery, W. J.; Brown, J.; y Nowak, Z. P. (1989): «AVHRR Image Navigation: Summary and Review», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 1175-1183.

Estébanez, J. y Bradshaw, R. (1978): *Técnicas de Cuantificación en Geografía*, Madrid, Tebar Flores.

Estes, J. E. y Lenger, L. W. (eds.) (1974): *Remote Sensing. Techniques for Environmental Analysis*, Santa Barbara, California, Hamilton Publishing Co.

Estes, J. E. y Simonett, D. S. (1975): «Fundamentals of image interpretation», en R. G. Reeves (ed.), *Manual of Remote Sensing*, Falls Church, American Society of Photogrammetry, pp. 869-1076.

European Commission (1993): *Corine Land Cover: Guide Technique*, Luxemburgo, Office for oficial publications of the European Union.

Eyton, J. R. (1983): «Landsat multitemporal color composites», *Photogrammetric Engineering and Remote Sensing*, 49, pp. 231-235.

Fernández, A.; Illera, P. y Casanova, J. L. (1997): «Automatic mapping of surfaces affected by forest fires in Spain using AVHRR NDVI composite image data», *Remote Sensing of Environment*, 60, pp. 153-162.

Fernández-Gustiz, E. (2001): «Generación de Rutinas para la Detección de Cambios. Aplicación al Crecimiento Urbano de Madrid», *Proyecto Fin de Carrera*, Departamento de Geografía, Universidad de Alcalá.

Ferns, D. C. y Press, N. P. (1988): «Microcomputers and mass storage devices for image processing», en J. P. Muller (ed.), *Digital Image Processing in Remote Sensing*, Londres, Taylor & Francis, pp. 105-121.

Ferrare, R. A.; Fraser, R. S. y Kaufman, Y. J. (1990): «Satellite measurements of large-scale air pollution: measurements of forest fire smoke», *Journal of Geophysical Research*, 95, pp. 9.911-9.925.

Ferris, J. y Congalton, R. G. (1989): «Satellite and Geographic Information System estimates of Colorado River Basin snowpack», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 1629-1635.

Fisher, P. F. y Pathirana, S. (1990): «The evaluation of fuzzy membership of land cover classes in the suburban zone», *Remote Sensing of Environment*, 34, pp. 121-132.

Fitzegarld, R. W. y Lees, B. G. (1994): «Assessing the classification accuracy of multisource remote sensing data», *Remote Sensing of Environment*, 47, pp. 362-368.

Fitzpatrick-Lins, K. (1978): «Accuracy and consistency comparisons of land use and land cover maps made from high-altitude photographs and Landsat multispectral imagery», *Journal Research U.S. Geological Survey*, 6, pp. 23-40.

Flasse, S. P. y Ceccato, P. (1996): «A contextual algorithm for AVHRR fire detection», *International Journal of Remote Sensing*, 17, pp. 419-424.

Florini, A. M. y Dehqanzada, Y. A. (2001): «The global politics of commercial observation satellites», en J. C. Baker, K. M. O'Connell y R. A. Williamson (eds.), *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 433-448.

Foody, G. y Curran, P. (1994): *Environmental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons.

Foody, G. M. (1992): «A fuzzy sets approach to the representation of vegetation continua from remotely sensed data: en example from lowland heath», *Photogrammetric Engineering and Remote Sensing*, 58, pp. 221-225.

— (1995): «Using prior knowledge in artificial neural network classification with a minimal training set», *International Journal of Remote Sensing*, 16, pp. 301-312.

— (2001): «Monitoring the magnitude of land-cover change around the Southern limits of the Sahara», *Photogrammetric Engineering and Remote Sensing*, 67, pp. 841-847.

Foody, G. M. y D. P. Cox (1994): «Sub-pixel land-cover composition estimation using a linear mixture model and fuzzy membership functions», *International Journal of Remote Sensing*, 15, pp. 619-631.

Ford, J. P. (1980): *Seasat Views North America, the Caribbean, and Western Europe with Imaging Radar*, Pasadena, Jet Propulsion Laboratory Publications.

Fourty, T. y Baret, F. (1997): «Vegetation water and dry matter contents estimated from top-of-the atmosphere reflectance data: a simulation study», *Remote Sensing of Environment*, 61, pp. 34-45.

França, R. D. A.; Brustet, J. M. y Fonfan, J. (1995): «Multispectral remote sensing of biomass burning in West Africa», *Journal of Atmospheric Chemistry*, 22, pp. 81-110.

Francis, P. y Jones, P. (1984): *Images of Earth*, Londres, George Phillip and Son Ltd.

Franklin, J.; Logan, T. L.; Woodcock, C. E. y Strahler, A. H. (1986): «Coniferous forest classification and inventory using Landsat and digital terrain data», *IEEE Transactions on Geoscience and Remote Sensing*, GE-24, pp. 139-149.

Franklin, S. E. (ed.) (2001): *Remote sensing for sustainable forest management*, Boca Raton, Fla, Lewis.

Fraser, R. H., Li, Z. y Cihlar, J. (2000): «Hotspot and NDVI differencing synergy (HANDS): a new technique for burned area mapping over boreal forest», *Remote Sensing and Environment*, 74, pp. 362-376.

Friedl, M. A. y Brodley, C. E. (1997): «Decision tree classification of land cover from remotely sensed data», *Remote Sensing of Environment*, 61, pp. 399-409.

Friedl, M. A.; Brodley, C. E. y Strahler, A. H. (1999): «Maximizing land cover classification accuracies produced by decision trees at continental to global scales», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 969-977.

Frohn, R. C. (1998): *Remote Sensing for Landscape Ecology. New Metric Indicators for Monitoring, Modeling and Asessment of Ecosystems*, Boca Raton, Lewis Publishers.

Fuller, D. O. y Fulk, M. (2000): «Comparison of NOAA-AVHRR and DMSP-OLS for operational fire monitoring in Kalimantan, Indonesia», *International Journal of Remote Sensing*, 21, pp. 181-187.

Fung, T. (1992): «Land Use and Land Cover Change Detection with Lansat MSS and SPOT-HRV Data in Hong Kong», *Geocarto International*, 7, pp. 33-40.

Fung, T. y LeDrew, E. (1987): «Application of principal components analysis to change detection», *Photogrammetric Engineering and Remote Sensing*, 53, pp. 1649-1658.

— (1988): «The determination of optimal threshold levels for change detection using various accuracy indices», *Photogrammetric Engineering and Remote Sensing*, 54, 1449-1454.

Gallo, K. P. y Flesch, T. K. (1989): «Large Area Crop monitoring with NOAA AVHRR: Estimating the Silking Stage of Corn Development», *Remote Sensing of Environment*, 27, pp. 73-80.

Gao, B. C. (1996): «NDWI. A normalized difference water index for remote sensing of vegetation liquid water from space», *Remote Sensing of Environment*, 58, pp. 257-266.

García, E.; Bradshaw, R. P. y Ocaña, M. C. (1986): «Análisis de los usos del suelo en la depresión de Antequera mediante la utilización del TM», *I Reunión Científica del Grupo de Trabajo en Teledetección*, Barcelona, Institut Cartografic de Catalunya, pp. 31-50.

Garguet-Duport, B. (1997): «Wavemerg: a multiresolution software for merging SPOT panchromatic and SPOT multispectral data», *Environmental modeling & Software*, 12, pp. 85-92.

Gates, D. M.; Keegan, H. J.; Schleter, J. C. y Weidner, V. R. (1965): «Spectral properties of plants», *Applied Optics*, 4, pp. 11-20.

Gausman, H. W. (1977): «Reflectance of leaf components», *Remote Sensing of Environment*, 6, pp. 1-9.

GDTA-CEE, X. X. (1982): *Recherche sur la Cartographie de l'Occupation des Sols par Télédetection*, Paris, IGN Département de Télédetection et de Cartographie Spatiale.

Gibson, P. y Power, C. H. (2000*a*): *Introductory Remote Sensing: Principles and Concepts*, Londres, Routledge.

— (2000*b*): *Introductory Remote Sensing: Digital Image Processing and Applications*, Londres, Routledge.

Gilabert, M. A., Conese C. y Maselli, F. (1994): «An atmospheric correction method for the automatic retrieval of surface reflectances from TM images», *International Journal of Remote Sensing*, 15, pp. 2065-2086.

Ginevan, M. E. (1979): «Testing land-use map accuracy: another look», *Photogrammetric Engineering and Remote Sensing*, 45, 1371-1377.

Girard, C. M. (1981): «Grassland mapping using satellite multitemporal data», en C. M. Girard, *Matching Remote Sensing Technologies and Their Applications*, Londres, Remote Sensing Society, pp. 111-122.

Goel, N. S. (1988): «Models of vegetation canopy reflectance and their use in estimation of biophysical parameters from reflectance data», *Remote Sensing Reviews*, 4, pp. 1-212.

Gogineni, S.; Ampe, J. y Budihardjo, A. (1991): «Radar Estimates of Soil Moisture Over the Konza Prairie», *International Journal of Remote Sensing*, 12, pp. 2425-2432.

Gong, P. (1994): «Integrated analysis of spatial data from multiple sources: an overview», *Canadian Journal of Remote Sensing*, 20, pp. 349-359.

— (1996): «Integrated analysis of spatial data from multiple sources: using evidential reasoning and artificial neural network techniques for geological mapping», *Photogrammetric Engineering and Remote Sensing*, 62, pp. 513-523.

Gong, P. y Howarth, P. J. (1990*a*): «The use of structural information for improving land-cover classification accuracies at the rural-urban fringe», *Remote Sensing of Environment*, 56, pp. 67-73.

— (1990*b*): «An assessment of some factors influencing multispectral land-cover classification», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 597-603.

— (1992): «Frequency-based contextual classification and gray-level vector reduction for land use identification», *Photogrammetric Engineering and Remote Sensing*, 58, pp. 423-437.

Gong, P.; Marceau, O. J. y Howarth, P. J. (1992): «A comparison of spatial feature extraction algorithms for land-use classification with SPOT-HRV data», *Remote Sensing of Environment*, 40, pp. 137-151.

Gong, P.; Miller, J. R. y Spanner, M. (1994): «Forest canopy closure from classification and spectral unmixing of scene components. Multisensor evaluation of an open canopy», *IEEE Transactions on Geoscience and Remote Sensing*, 32, pp. 1067-1079.

González, F. y López, S. (1991): «Using contextual information to improve land use classification of satellite images in Central Spain», *International Journal of Remote Sensing*, 12, pp. 2227-2235.

González, R. C. y Wintz, P. (1977): *Digital Image Processing*, Reading, Mass., Addison & Wesley.

Gopal, S. y Woodcock, C. (1996): «Remote sensing of forest change using artificial neural networks», *IEEE Transactions on Geoscience and Remote Sensing*, 34, pp. 398-404.

Gordon, D. K. y Philipson, R. (1986): «A texture-enhancement procedure for separating orchard from forest in Thematic Mapper data», *International Journal of Remote Sensing*, 7, pp. 301-304.

Gordon, S. I. (1980): «Utilizing Landsat imagery to monitor land use change: a case study in Ohio», *Remote Sensing of Environment*, 9, pp. 189-196.

GORS (1996): *Syria. Space Image Atlas*, Damascus, General Organization of Remote Sensing.

Goward, S. N.; Markham, B.; Dye, D. G.; Dulaney, W. y Yang, I. (1991): «Normalized difference vegetation index measurements from the Advanced Very High Resolution Radiometer», *Remote Sensing of Environment*, 35, pp. 257-277.

Gower, J. F. R. (ed.) (1994): *Oceanography from Space*, Plenum Press.

Green, A. A.; Berman, M.; Switzer, P. y Craig, M. D. (1988): «A transformation for ordering multispectral data in terms of image quality with implications for noise removal», *IEEE Transactions on Geoscience and Remote Sensing*, 26, pp. 65-74.

Green, K. (1994): «The potential and limitations of remote sensing and GIS providing ecological information, en V. A. Sample, *Remote Sensing and GIS in Ecosystem Management*, Washington, D.C., Island Press, pp. 327-336.

— (2000): «Selecting and interpreting high-resolution images», *Journal of Forestry*, 98, pp. 37-39.

Griffiths, G. H.; Smith, J. M.; Veitch, N. y Aspinall, R. (1993): «The ecological interpretation of satellite imagery with special reference to Bird Habitats», en R. Haines-Young, D. R. Green y S. Cousins, *Landscape Ecology and Geographic Information Systems*, Londres, Taylor & Francis, pp. 255-272.

Grover, K. D.; Quegan, S.; Yanasse, C. C. F. y Dutra, L. V. (1995): «Potencial Use of ERS-1 in Tropical Forest Monitoring. A study of the Tepajos National Forest, Brazil», *Earth Observation Quarterly*, 48, pp. 12-15.

Gulinck, H.; Walpot, D.; Janssens, P. y Dries, I. (1991): «The visualization of corridors in the landscape using SPOT data», en D. Saunders y R. J. Hobbs (eds.), *Nature Conservation 2: The role of corridors*, Surrey, Beatty and Sons, pp. 9-17.

Gurney, C. M. y Townshend, J. R. G. (1983): «The use of contextual information in the classification of remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 49, pp. 55-64.

Gutiérrez, J. y Gould, M. (1994): *S.I.G.: Sistemas de Información Geográfica*, Madrid, Síntesis.

Gutman, G. G. (1994): «Global data on land surface parameters from NOAA-AVHRR for use in numerical climate model», *Journal of Climate*, 7, pp. 669-680.

Guyot, G. y Gu, X. F. (1994): «Effect of radiometric corrections on NDVI determined from SPOT-HRV and Landsat-TM data», *Remote Sensing of Environment*, 49, pp. 169-180.

Guyot, G.; Guyon, D. y Riom, J. (1989): «Factors affecting the spectral response of forest canopies: a review», *Geocarto International*, 4, pp. 3-18.

Haack, B.; Bryant, N. y Adams, S. (1987): «An assessment of Landsat MSS and TM data for urban and near-urban land-cover digital classification», *Remote Sensing of Environment*, 21, pp. 201-213.

Haines-Young, R.; Green, D. R. y Cousins, S. H. (eds.) (1993): *Landscape Ecology and Geographic Information Systems*, Londres, Taylor and Francis.

Hall, D. K. (1988): «Assessment of Polar climate change using satellite technology», *Reviews of Geophysics*, 26, pp. 26-39.

Hall, D. K. y Martinec, J. (1985): *Remote Sensing of Ice and Snow*, Londres, Chapman and Hall.

Hall, F. G.; Strebel, D. E.; Nickeson, E. y Goetz, S. J. (1991*a*): «Radiometric rectification: toward a common radiometric response among multidate multisensor images», *Remote Sensing of Environment*, 35, pp. 11-27.

Hall, F. G.; Botkin, D. B.; Strebel, D. E.; Woods, K. D. y Goetz, S. J. (1991*b*): «Large-scale patterns of forest succession as determined by remote sensing», *Ecology*, 72, pp. 628-640.
Hall, R. J.; Crown, P. H. y Titus, S. J. (1984): «Change detection methodology for aspen defoliation with Landsat MSS digital data», *Canadian Journal of Remote Sensing*, 10, pp. 135-142.
Hand, D. J. (1981): *Discrimination and Classification*, Nueva York, John Wiley and Sons.
Hansen, M.; Dubayah, R. y Defries, R. (1996): «Classification trees: an alternative to traditional land cover classifiers», *International Journal of Remote Sensing*, 17, 1075-1081.
Haralick, R. M., Shanmugan, K. y Dinstein, I. (1973): «Textural features for image classification», *IEEE Transactions on Systems, Man and Cybernetics*, SMC-3, pp. 610-621.
Hardy, C. C. y Burgan, R. E. (1999): «Evaluation of NDVI for monitoring live moisture in three vegetation types of the Western U.S.», *Photogrammetric Engineering and Remote Sensing*, 65, pp. 603-610.
Hargrove, W. W.; Gardner, R. H.; Turner, M. G.; Romme, W. H. y Despain, D. G. (2000): «Simulating fire patterns in heterogeneous landscapes», *Ecological Modelling*, 135, pp.243-263.
Harnapp, V. (1978): «Landsat imagery: a tool for updating land use in Gulf Coast Mexico», *Journal of Geography*, 78, pp. 141-144.
Harper, D. (1983): *Eye in the Sky. Introduction to Remote Sensing*, 2.ª ed., Montreal, Multiscience Publications Ltd.
Harris, R. (1987): *Satellite Remote Sensing. An Introduction*, Londres, Routledge and Kegan Paul.
Hart, W. G. (1975): «The use of Skylab data to study the early detection of insect infestations and density and distribution of host plants», *NASA Earth Resources Survey Symposium*, pp. 203-220.
Hay, A. M. (1979): «Sampling designs to test land-use map accuracy», *Photogrammetric Engineering and Remote Sensing*, 45, pp. 529-533.
— (1988): «The derivation of global estimates from a confusion matrix», *International Journal of Remote Sensing*, 9, pp. 1385-1398.
Hazel, G. G. (2001): «Object-Level Change Detection in Spectral Imagery», *IEEE Transactions on Geoscience and Remote Sensing*, 39, 553-561.
Henderson, F. M. y Lewis, A. J. (eds.) (1998): *Principals and Applications of Imaging Radar*, Manual of Remote Sensing, Nueva York, John Wiley & Sons, Inc.
Henderson, R. M. (1983): «A comparison of SAR brightness levels and urban land-cover classes», *Photogrammetric Engineering and Remote Sensing*, 49, pp. 1585-1591.
Henebry, G. M. (1993): «Detecting change in grasslands using measures of spatial dependence with Landsat-TM data», *Remote Sensing of Environment*, 46, pp. 223-234.
Heo, J. y Fitzhugh, T. W. (2000): «A standardized radiometric normalization method for change detection using remotely sensed imagery», *Photogrammetric Engineering and Remote Sensing*, 66, pp. 173-181.
Hepner, G.; Logan, T.; Ritter, N. y Bryant, N. (1990): «Artificial neural network classification using a minimal training set: comparison to conventional supervised classification», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 469-473.
Heric, M.; Lucas, C. y Devine, C. (1996): «The Open Skies Treaty: qualitative utility evaluations of aircraft reconnaissance and commercial satellite imagery», *Photogrammetric Engineering and Remote Sensing*, 62, pp. 279-284.
Herrera, V. (2001): «Estudio del crecimiento urbano de la ciudad de Valdivia (Chile) a través del uso integrado de imágenes de satélite, SIG y equipos GPS», *Revista Española de Teledetección*, 15, pp. 69-78.
Hervás, J. (1987): «La utilidad de análisis de componentes principales en cartografía litológica. Su aplicación a imágenes Landsat-TM y MSS del macizo ultrabásico de Ronda», *II Reunión Nac. Grupo Trabajo Teledetección*, Valencia, pp. 50-52.

Hervás, J. y Rosin, P. L. (2001): «Tratamiento digital de imágenes de teledetección en el espectro óptico para el reconocimiento y control de deslizamientos», *V Simposio Nacional sobre Taludes y Laderas Inestables. Madrid*, Madrid, CEDEX, Ministerio de Fomento, pp. 63-74.
Hewitson, B. C. y Crane, R. G. (eds.) (1994): *Neural Nets: Applications in Geography*, Dordrecht, Kluwer Academic Publishers.
Hill, J. y Sturm, B. (1991): «Radiometric correction of multitemporal Thematic Mapper data for use in agricultural land-cover classification and vegetation monitoring», *International Journal of Remote Sensing*, 12, pp. 1471-1491.
Hilwig, F. W. (1980): «Visual interpretation of multitemporal Landsat data for inventories of natural resources», *ITC Journal*, 2, pp. 297-327.
Hixson, M.; Scholz, D.; Fuhs, N. y Akiyama, T. (1980): «Evaluation of several schemes for classification of remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 46, pp. 1547-1553.
Hlavka, C. A. y Spanner, M. A. (1995): «Unmixing AVHRR imagery to assess clearcuts and forest regrowth in Oregon», *IEEE Transactions on Geoscience and Remote Sensing*, 33, pp. 788-795.
Ho, D. y Asem, A. (1986): «NOAA AVHRR image referencing», *International Journal of Remote Sensing*, 7, pp. 895-904.
Hobbs, R. J. y Mooney, H. A. (1990): *Remote Sensing of Biosphere Functioning*, Nueva York, Springer-Verlag.
Hoffer, R. M. (1994): «Challenges in developing and applying remote sensing to ecosystem management», en V. A. Sample (ed.), *Remote Sensing and GIS in Ecosystem Management*, Washington, D.C., Island Press, pp. 25-40.
Hoffer, R. M. y Fleming, M. D. (1978): *Mapping vegetative cover by computer-aided analysis of satellite data*, Purdue, LARS, Technical Report 011178.
Hoffer, R. M. y Swain, P. H. (1980): «Computer processing of satellite data for assessing agriculture, forest, and rangeland resources», *14th Intern. Soc. of Photog.*, Hamburgo, pp. 437-446.
Holben, B. y Justice, C. (1981): «An examination of spectral band ratioing to reduce the topographic effect on remotely sensed data, *International Journal of Remote Sensing*, 2, pp. 115-133.
Holben, B. N. (1980): «Spectral assessment of soybean leaf area and leaf biomass», *Photogrammetric Engineering and Remote Sensing*, 46, pp. 651-656.
— (1986): «Characteristics of maximum-value composite images from temporal AVHRR data», *International Journal of Remote Sensing*, 7, pp. 1417-1434.
Holben, B. N. y Shimabukuro, Y. E. (1993): «Linear mixing model applied to coarse spatial resolution data from multispectral satellite sensors», *International Journal of Remote Sensing*, 14, pp. 2231-2240.
Holz, R. K. (ed.) (1973): *The Surveillant Science. Remote Sensing of the Environment*, Boston, Houghton Mifflin Company.
Hopkins, P. F.; Maclean, A. L. y Lillesand, T. M. (1988): «Assessments of Thematic Mapper imagery for forestry applications under lake states conditions», *Photogrammetric Engineering and Remote Sensing*, 54, pp. 61-68.
Hord, R. M. (1982): *Digital Image Processing of Remotely Sensed Data*, Nueva York, Academic Press.
— (1986): *Remote Sensing. Methods and Applications*, Nueva York, John Wiley and Sons.
Hord, R. M. y Brooner, W. (1976): «Land use map accuracy criteria», *Photogrammetric Engineering and Remote Sensing*, 42, pp. 671-677.

Horler, D. N. H.; Dockray, M. y Barber, J. (1983): «The red edge of plant leaf reflectance», *International Journal of Remote Sensing*, 4, pp. 273-288.

Howard, J. A. (1991): *Remote Sensing of Forest Resources*, Londres, Chapman & Hall.

Howarth, P. J. y Boasson, E. (1983): «Landsat digital enhancements for change detection in urban environments», *Remote Sensing of Environment*, 13, pp. 149-169.

Howarth, P. J. y Wickware, G. M. (1981): «Procedures for change detection using Landsat digital data», *International Journal of Remote Sensing*, 2, pp. 277-291.

Hudson, W. D. y Ramn, C. W. (1987): «Correct formulation of the kappa coefficient of agreement», *Photogrammetric Engineering and Remote Sensing*, 53, pp. 421-422.

Huemmrich, K. F. (2001): «The GeoSail model: a simple addition to the SAIL model to describe discontinuous canopy reflectance», *Remote Sensing of Environment*, 75, pp. 423-431.

Huete, A.; Justice, C. y Liu, H. (1994): «Development of vegetation and soil indices for MODIS-EOS», *Remote Sensing of Environment*, 49, pp. 224-234.

Huete, A. R. (1987): «Spectral signatures and vegetation indices», *II Reunión Nac. del Grupo de Trabajo en Teledetección*, Valencia, Asociación Española de Teledetección, pp. 13-26.

— (1988): «A soil-adjusted vegetation index (SAVI), *Remote Sensing of Environment*, 25, pp. 295-309.

Huete, A. R.; Hua, G.; Qi, J.; Chehbouni, A. y van Leeuwen, W. J. D. (1992): «Normalization of Multidirectional Red and NIR reflectances with the SAVI», *Remote Sensing of Environment*, 41, pp. 143-154.

Huffaker, R. M.; Lawrence, T. R.; Post, M. J.; Priestley, J. T.; Hall, F. F.; Richter, R. A. y Keller, R. J. (1984): «Feasibility studies for a global wind measuring satellite system (Wyndsat). Analysis of simulated performance», *Applied Optics*, 23, pp. 2523-2534.

Hunt, E. R. y Rock, B. N. (1989): «Detection of changes in leaf water content using near and middle-infrared reflectances», *Remote Sensing of Environment*, 30, pp. 43-54.

Hunt, E. R.; Rock, B. N. y Nobel, P. S. (1987): «Measurement of leaf relative water content by infrared reflectance», *Remote Sensing of Environment*, 22, pp. 429-435.

Hutchinson, C. F. (1982): «Techniques for combining Landsat and ancillary data for digital classification improvement», *Photogrammetric Engineering and Remote Sensing*, 48, pp. 123-130.

Hyatt, E. (1988): *Keyguide to Information Sources in Remote Sensing*, Londres, Mansell Publ. Ltd.

Hyyppa, J. y Hallikainen, M. (1996): «Applicability of Airborne Profiling Radar to Forest Inventory», *Remote Sensing of Environment*, 57, pp. 39-57.

Illera, P.; Fernández, A. y Delgado, J. A. (1996): «Temporal evolution of the NDVI as an indicator of forest fire danger», *International Journal of Remote Sensing*, 17, pp. 1093-1105.

Ingebritsen, S. E. y Lyon, R. J. P. (1985): «Principal components analysis of multitemporal image pairs», *International Journal of Remote Sensing*, 6, pp. 687-695.

Irons, J. R. y Kennard, R. L. (1986): «The utility of Thematic Mapper sensor characteristics for surface mine monitoring», *Photogrammetric Engineering and Remote Sensing*, 52, pp. 389-396.

Itten, K. I. y Meyer, P. (1993): «Geometric and Radiometric Correction of TM Data of Mountainous Forested Areas», *IEEE Transactions on Geoscience and Remote Sensing*, 31, pp. 764-770.

Iverson, L. R.; Cook, E. A. y Graham, R. L. (1989): «A technique for extrapolating and validating forest cover across large regions. Calibrating AVHRR data with TM data», *International Journal of Remote Sensing*, 10, pp. 1805-1812.

Jackson, R. D. y Ezra, C. E. (1985): «Spectral response of cotton to suddenly induced water stress», *International Journal Remote Sensing*, 6, pp. 177-185.

Jackson, R. D.; Pinter, P. J.; Reginato, R. J. y Idso, S. B. (1986): «Detection and evaluation of

plant stress for crop management decisions», *IEEE Transactions on Geoscience and Remote Sensing*, 24, pp. 99-106.

Jacquemoud, S. (1990): «PROSPECT: a model to leaf optical properties spectra», *Remote Sensing of Environment*, 34, pp. 74-91.

— (1993): «Inversion of the PROSPECT+SAIL canopy reflectance model from AVIRIS equivalent spectra: theoretical study», *Remote Sensing of Environment*, 44, pp. 281-292.

Jacquemoud, S.; Bacour, C.; Poilve, H. y Frangi, J. P. (2000): «Comparison of Four Radiative Transfer Models to Simulate Plant Canopies Reflectance: Direct and Inverse Mode», *Remote Sensing of Environment*, 74, pp. 471-481.

Jakubauskas, M. E.; Lulla, K. P. y Mausel, P. W. (1990): «Assessment of vegetation change in a fire-altered forest landscape», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 371-377.

Jensen, J. R. (1981): «Urban change detection mapping using Landsat digital data», *The American Cartographer*, 8, pp. 127-147.

— (1996): *Introductory Digital Image Processing. A Remote Sensing Perspective*, 2.ª edición, Upper Saddle River, N.J., Prentice-Hall.

— (2000): *Remote Sensing of the Environment. An Earth Resource Perspective*, Upper Saddle River, N.J., Prentice-Hall.

Jensen, J. R. *et al.* (1983): «Urban/Suburban land use analysis», en R. N. Colwell, *Manual of Remote Sensing*, Falls Church, American Society of Photogrammetry, pp. 1571-1666.

Ji, W.; Civco, D. L. y Kennard, W. C. (1992): «Satellite remote bathymetry: a new mechanism for modelling», *Photogrammetric Engineering & Remote Sensing*, 58, pp. 545-549.

Johnston, R. J. (1978): *Multivariate Statistical Analysis in Geography*, Londres, Longman.

Joly, G.; Verger, F. y Crettez, J. P. (1983): «Classification des donées Landsat unitemporelles et multitemporelles par la transformation de Karhunen-Loève. Application à l'Anse de l'Aiguillon», *L'Espace Géographique*, 2, pp. 125-141.

Juppenlatz, M. y Tian, X. (1996): *Geographic Information Systems and Remote Sensing: guidelines for use by planners and decision makers*, Roseville, Australia, McGraw-Hill.

Justice, C. O. y Townshend, J. R. G. (1981): «The use of Landsat data for land cover inventories of Mediterranean lands», en J. R. G. Townshend (ed.), *Terrain Analysis and Remote Sensing*, Londres, George Allen & Unwin, pp. 135-153.

Kasischke, E. S.; French, N. H.; Harrell, P.; Christensen, N. L.; Ustin, S. L. y Barry, D. (1993): «Monitoring of wildfires in Boreal Forests using large area AVHRR NDVI composite image data», *Remote Sensing of Environment*, 45, pp. 61-71.

Kaufman, Y. y Tanré, D. (1992): «Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS», *IEEE Transactions on Geoscience and Remote Sensing*, 30, pp. 261-270.

Kaufman, Y. J.; Fraser, R. S. y Ferrare, R. A. (1990): «Satellite measurements of large-scale air pollution: methods», *Journal of Geophysical Research*, 95, pp. 9.895-9.909.

Kauth, R. J. y Thomas, G. S. (1976): «The Tasseled Cap. A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat», *Symp. on Machine Processing of Remotely Sensed Data*, Purdue, pp. 41-51.

Kayser, B., Hubschman, J. y Selleron, G. (1992): *L'Europe vue de l'Espace*, Toulouse, Solar et Daniel Briand, SPOT-CNES.

Kennedy, P. (1989): «Monitoring the vegetation of Tunisian grazing lands using the Normalized Difference Vegetation Index», *Ambio*, 18, pp. 119-123.

Kennedy, P. J.; Belward, A. S. y Grégoire, J. M. (1994): «An improved approach to fire monitoring in West Africa using AVHRR data», *International Journal of Remote Sensing*, 15, pp. 2235-2255.

Kerdiles, H. y Grondona, M. O. (1995): «NOAA-AVHRR NDVI decomposition and subpixel

classification using linear mixing in the Argentinean Pampa», *International Journal of Remote Sensing*, 95, pp. 1303-1325.

Kerr, Y. H.; Lagouarde, J. P. y Imbernon, J. (1992): «Accurate land surface temperature retrieval from AVHRR data with use of an improved Split Window algorithm», *Remote Sensing of Environment*, 41, pp. 197-209.

Ketting, R. L. y Landgrebe, D. A. (1975): «Classification of multispectral image data by extraction and classification of homogeneous objects», *Symposium on Machine Classification of Remotely Sensed Data*, West Lafayette, pp. 1-11.

Kidwell, K. B. (1990): *Global Vegetation Index, User's guide*, Washington, D.C, NOAA/NESDIS/NCDC.

— (1991): *NOAA Polar Orbiter Data (TIROS-N, NOAA-6, NOAA-7, NOAA-8, NOAA-9, NOAA-10, NOAA-11, and NOAA-12), Users Guide*, Washington, D.C., NOAA/NESDIS.

Kiefer, R. W. (1988): *Survey of Photogrammetry and Remote Sensing Programs and Courses in the United States and Canada*, Falls Church, American Society of Photogrammetry and Remote Sensing.

King, M. D.; Kaufman, Y. J.; Tanré, D. y Nakajima, T. (1999): «Remote Sensing of Troposheric Aerosols from Space: Past, Present and Future», *Bulletin of the American Meteorological Society*, 80, pp. 2229-2259.

King, R. B. (1981): «An evaluation of Landsat-3 RBV imagery for obtaining environmental information in Tanzania», *Matching Remote Sensing Technologies and their Applications*, Londres, Remote Sensing Society, pp. 85-95.

Knipling, E. B. (1970): «Physical and Physiological basis for the reflectance of visible and near-infrared radiation from vegetation, *Remote Sensing of Environment*, 1, pp. 155-159.

Kobayashi, T. (1987): «Techniques for laser remote sensing of the environment», *Remote Sensing Reviews*, 3, pp. 1-57.

Kogan, F. N. (1990): «Remote sensing of weather impacts on vegetation in non-homogeneous areas», *International Journal of Remote Sensing*, 11, pp. 1405-1419.

Konecny, G. (1986): «First Results of the European Spacelab Photogrammetric Camera Mission», en K. H. Szekielda (ed.), *Satellite Remote Sensing for Resources Development*, Londres, Graham and Trotman Ltd., pp. 115-121.

Koopmans, B. N. (1983): «Spaceborne imaging radars, present and future», *ITC Journal*, 83, pp. 223-231.

Koutsias, N.; Karteris, M. y Chuvieco, E. (2000): «The use of intensity-hue-saturation transformation of Landsat-5 Thematic Mapper data for burned land mapping», *Photogrammetric Engineering and Remote Sensing*, 66, pp. 829-839.

Kramer, H. J. (1994): «Observation of the Earth and its Environment», *Survey and Missions and Sensors*, Berlin, Springer-Verlag.

Krasnopolsky, V. M. y Breaker, L. C. (1994): «The problem of AVHRR image navigation revisited», *International Journal of Remote Sensing*, 15, pp. 979-1008.

Kruse, F. A.; Lefkoff, A. B. y Dietz, J. B. (1993*a*): «Expert System-Based Mineral Mapping in Northern Death Valley, California/Nevada, using the Airborne Visible/Infrared Imaging Spectrometer (AVIRIS)», *Remote Sensing of Environment*, 44, pp. 309-336.

Kruse, F. A.; Lefkoff, A. B.; Boardman, J. B.; Heidebrecht, K. B.; Shapiro, A. T.; Barloon, P. J. y Goetz, A. F. H. (1993*b*): «The Spectral Image Processing (SIPS) - Interactive Visualization and Analysis of Imaging Spectrometer Data», *Remote Sensing of Environment*, 44, pp. 145-163.

Kumar, R. y Silva, L. F. (1977): «Separability of agricultural cover types by remote sensing in the visible and infrared wavelength regions», *IEEE Transactions on Geoscience Electronics*, 15, pp. 49-59.

Kupiec, J. A. y Curran, P. J. (1995): «Decoupling effects of the canopy and foliar biochemicals in AVIRIS spectra», *International Journal of Remote Sensing*, 16, pp. 1731-1739.

Kuusk, A. (2001): «A two-layer canopy reflectance model», *Journal of Quantitative Spectroscopy & Radiative Transfer*, 71, pp. 1–9.

Labrandero, J. L. (1978): *Aplicación de métodos digitales al reconocimiento de suelos mediante sensores remotos*, Departamento de Geología, Universidad Autónoma de Madrid.

Labuto, M. R. (1991): «Cloud detection using "yellowness" parameter from "tasseled cap" transformation in a Landsat-MSS image», *V Simp. Latinoam. de Percepción Remota*, Curco, pp. 220-228.

Lachowski, H.; Maus, P. y Platt, B. (1992): «Integrating remote sensing with GIS. Procedures from the forest service», *Journal of Forestry*, 90, pp. 16-21.

Lam, N. S. (1990): «Description and measurement of Landsat-TM images using fractals», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 187-195.

Lauer, D. T.; Estes, J. E.; Jensen, J. R. y Greenlee, D. D. (1991): «Institutional issues affecting the integration and use of remotely sensed data and geographic information systems», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 647-654.

Leblon, B. (2001): «Forest Wildfire Hazard Monitoring Using Remote Sensing: A Review», *Remote Sensing Reviews*, 20, pp. 1-57.

Leckie, D. G. (1990): «Synergism of synthetic aperture radar and visible/infrared data for forest type discrimination», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 1237-1246.

Lee, T.; Richards, J. A. y Swain, P. H. (1987): «Probabilistic and evidential approaches for multisource data analysis», *IEEE Transactions on Geoscience and Remote Sensing*, 25, pp. 283-292.

Lefsky, M. A.; Cohen, W. B.; Acker, S. A.; Parker, G. G.; Spies, T. A. y Harding, D. (1999): «Lidar remote sensing of the canopy structure and biophysical properties of Douglas-fir western hemlock forests», *Remote Sensing of Environment*, 70, pp. 339-361.

Leghorn, R. S. y Herken, G. (2001): «The origins and evolution of openness in overhead global observations», en J. C. Baker, K. M. O'Connell y R. A. Williamson (eds.), *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 17-36.

Leprieur, C.; Durand, J. M. y Peyron, J. L. (1988): «Influence of Topography on Forest Reflectance Using Landsat Thematic Mapper and Digital Terrain Data», *Photogrammetry Engineering & Remote Sensing*, 54, pp. 491-496.

Lewis, A. J.; Henderson, F. M. y Holcomb, D. W. (1998): «Radar Fundamentals: The Geoscience Perspective», en F. M. Henderson y A. J. Lewis (eds.), *Principals and Applications of Imaging Radar*, Nueva York, John Wiley & Sons, Inc., pp. 131-182.

Li, H. y Reynolds, J. F. (1993): «A new contagion index to quantify spatial patterns of landscapes», *Landscape Ecology*, 8, pp. 155-162.

Li, X. y Strahler, A. H. (1986): «Geometric-optical bidirectional reflectance modeling of a conifer forest canopy», *IEEE Transactions on Geoscience and Remote Sensing*, 24, pp. 906-919.

Lillesand, T. M. y Kiefer, R. W. (2000): *Remote Sensing and Image Interpretation*, 4.ª edición, Nueva York, John Wiley and Sons.

Linden, D. S. (2000): «Videography for Foresters», *Journal of Forestry*, 98, pp. 25-27.

Links, H. F. (1976): «Land-use mapping from Skylab S190B photography», *Photogrammetric Engineering and Remote Sensing*, 42, pp. 301-307.

Lira, J. (1987): *La percepción remota. Nuestros ojos desde el espacio*, México, Fondo de Cultura Económica.

Llop, R.; González, F.; Cuevas, J. M. y López, S. (1987): «Utilización de los datos SIR-A para el reconocimiento de los usos del suelo en la región centro española», *I Reunión Científica del Grupo de Trabajo en Teledetección*, Barcelona, pp. 115-137.

Lo, C. P. (1986): *Applied Remote Sensing*, Nueva York, Logman Scientific and Technical.

Lo, C. P. y Welch, R. (1977): «Chinese urban population estimates», *Annals Association of American Geographers*, 47, pp. 246-253.

Lo, T. H. C.; Scarpace, F. L. y Lillesand, T. M. (1986): «Use of multitemporal spectral profiles in agricultural land-cover classification», *Photogrammetric Engineering and Remote Sensing*, 52, pp. 535-544.

Lobo, A. (1997): «Image Segmentation and Discriminant Analysis for the Identification of Land Cover Units in Ecology», *IEEE Transactions on Geoscience and Remote Sensing*, 35, pp. 1136-1145.

López, M. J. (1991): «La temperatura del mar balear a partir de imágenes de satélite», tesis doctoral, Departamento de Geografía, Universidad de Valencia.

López, M. J. y Caselles, V. (1989): «A multitemporal study of chlorophyll. A concentration in the Albufera lagoon of Valencia, Spain, using Thematic Mapper data», *International Journal of Remote Sensing*, 11, pp. 301-311.

López, S.; González, F.; Llop, R. y Cuevas, J. M. (1991): «An evaluation of the utility of NOAA AVHRR images for monitoring forest fire risk in Spain», *International Journal of Remote Sensing*, 12, pp. 1841-1851.

López-Baeza, E. (1991): «Climatología desde satélites», en G. S. y J. Meliá (eds.), *La Teledetección en el Seguimiento de los Fenómenos Naturales. Recursos Renovables: Agricultura*, Valencia, Universitat de València, Departament de Termodinàmica, pp. 325-344.

López Vizoso, J. M. (1987): «Cartografía automática de la ocupación del suelo en la comarca ferrolana», *Estudios Territoriales*, 25, pp. 65-77.

— (1989*a*): «La observación de la Tierra desde el espacio: el mapa de ocupación del suelo de la Comunidad Económica Europea», *Estudios Geográficos*, 50, pp. 409-434.

— (1989*b*): «Aplicaciones del tratamiento de imágenes espaciales de alta resolución a los estudios de ordenación del territorio en Galicia», tesis doctoral, Santiago de Compostela.

Loveland, T. R.; Merchant, J. W.; Ohlen, D. O. y Brown, J. F. (1991): «Development of a Land-Cover Characteristics Database for the Conterminous U.S.», *Photogrammetric Engineering & Remote Sensing*, 57, pp. 1453-1463.

Lucas, R. M.; Honzak, M.; Foody, G. M.; Curran, P. J. y Corves, C. (1993): «Characterizing tropical secondary forests using multi-temporal Landsat sensor imagery», *International Journal of Remote Sensing*, 14, pp. 3016-3067.

Lulla, K. (1985): «Some observations on geobotanical remote sensing and mineral prospecting», *Canadian Journal of Remote Sensing*, 11, pp. 17-38.

— (1993): «Space shuttle earth observations database for global urban applications», en K. N. Au (ed.), *Cities of the World as Seen from Space*, Hong Kong, Geocarto International, pp. 15-19.

Lulla, K. P. y Dessinov, L. V. (eds.) (2000): *Dynamic Earth Environments. Remote Sensing Observations from Shuttle - Mir Missions*, Nueva York, John Wiley and Sons.

Lusch, R. (1989): «Spectral characteristics of land surfaces», en M. D. Nellis, R. Lougeay y K. Lulla (eds.), *Current Trends in Remote Sensing Education*, Hong-Kong, Geocarto International Centre, pp. 81-86.

Madsen, S. N. y Zebker, H. A. (1998): «Imaging Radar Interferometry», en F. M. Henderson y A. J. Lewis (eds.), *Principals and Applications of Imaging Radar*, Nueva York, John Wiley & Sons, Inc., pp. 359-380.

Maguire, D. J.; Goodchild, M. F. y Rhind, D. W. (eds.) (1991): *Geographical Information Systems. Principles and Applications*, Londres, Longman.

Malingreau, J. P.; Tucker, C. J. y Laporte, N. (1989): «AVHRR for monitoring global tropical deforestation», *International Journal of Remote Sensing*, 10, pp. 855-867.

Margaritz, M.; Kaufman, A.; Paul, M.; B. E. y Hollos, G. (1990): «A new method to determine regional evapotranspiration», *Water Resources Research*, 26, pp. 1759-1762.

Markham, G. L. y Townshend, J. R. G. (1981): «Land cover classification accuracy as a function of sensor spatial resolution», *15th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor, pp. 1075-1090.

Marsh, S. E.; Switzer, P.; Kowalick, W. S. y Lyon, R. J. P. (1980): «Resolving the percentage of component terrains within single resolution elements», *Photogrammetric Engineering and Remote Sensing*, 46, pp. 1079-1086.

Martin, F. C. (1985): «Using a geographic information system for forest land mapping and management», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 1753-1759.

Martin, L. R. G. (1989): «Accuracy assessment of Landsat-based visual change detection methods applied to the rural-urban fringe», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 209-215.

Martín, M. P. (1998): «Cartografía e inventario de incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR», tesis doctoral, Departamento de Geografía, Universidad de Alcalá.

Martín, M. P. y Chuvieco, E. (1995): «Mapping and evaluation of burned land from multitemporal analysis of AVHRR NDVI images», *EARSeL Advances in Remote Sensing*, 4, (3), pp. 7-13.

— (1998): «Cartografía de grandes incendios forestales en la Península Ibérica a partir de imágenes NOAA-AVHRR», *Serie Geográfica*, 7, pp. 109-128.

Martín, M. P.; Ceccato, P.; Flasse, S. y Downey, I. (1999): «Fire detection and fire growth monitoring using satellite data», en E. Chuvieco (ed.), *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlín, Springer-Verlag, pp. 101-122.

Martínez Vega, J. (1989): «Propuesta metodológica para la presentación cartográfica de los tipos dinámicos de ocupación y uso del suelo», *Estudios Geográficos*, 39, pp. 235-258.

— (1996): «Una revisión sobre las imágenes espaciales como fuentes cartográficas», *Revista Española de Teledetección*, 6, pp. 37-50.

— (1997): «Una revisión sobre las imágenes espaciales como recursos didácticos», *Revista Española de Teledetección*, 8, pp. 15-26.

Marx, C. y Hildebrandt, G. (1978): «Qualitative and quantitative interpretation of Landsat MSS data to forest cover mapping in Germany», *International Symposium on Remote Sensing for Observation and Inventoty of Earth Resources and the Endangered Environment*, Freiburg, pp. 1791-1804.

Maselli, F.; Conese, C.; De Filippis, T. y Norcini, S. (1995): «Estimation of forest parameters through fuzzy classification of TM data», *IEEE Transactions on Geoscience and Remote Sensing*, 33, pp. 77-84.

Maselli, F.; Petkov, L.; Maracchi, G. y Conese, C. (1996): «Eco-climatic classification of Tuscany through NOAA-AVHRR data», *International Journal of Remote Sensing*, 17, pp. 2369-2384.

Massonet, D.; Briole, P. y Arnaud, A. (1995): «Deflation of Mount Etna monitored by spaceborne radar interferometry», *Nature*, 375, pp. 567-570.

Massonet, D.; Rossi, M.; Carmona, C.; Adragna, F.; Peltzer, G.; Feigl, K.; y Rabaute, T. (1993): «The displacement field of the Landers Earthquake mapped by radar interferometry», *Nature*, 364, pp. 138-142.

Mather, P. M. (1998): *Computer Processing of Remotely Sensed Images*, 2.ª edición, Chichester, John Wiley & Sons.

— (1999): «Land Cover classification revisited», en P. M. Atkinson y N. J. Tate, *Advances in Remote Sensing and GIS analysis*, Chichester, John Wiley & Sons, pp. 7-16.

Mazer, A. S.; Martin, M.; Lee, M. y Solomon, J. E. (1988): «Image Processing software for Imaging Spectrometry Data Analysis», *Remote Sensing of Environment*, 24, pp. 201-210.

McCloy, K. R. (1995): *Resource Management Information Systems. Process and Practice*, Londres, Taylor & Francis.

McDonald, R. A. (1995): «CORONA - success for space reconnaissance, a look into the Cold War, and a revolution for intelligence», *Photogrammetric Engineering and Remote Sensing*, 61, pp. 689-720.

McGwire, K. C. (1996): «Cross-validated assessment of geometric accuracy», *Photogrammetric Engineering and Remote Sensing*, 62, 1179-1187.

Measures, R. M. (1984): *Laser Remote Sensing*, Nueva York, John Wiley.

Meliá, J. y Sobrino, J. A. (1987): «A study on the utilization of SIR-A data for population estimation in the Eastern part of Spain», *Geocarto International*, 2, pp. 33-38.

Meliá, J.; Gandia, S. y Caselles, V. (1986): «Teledetección y signaturas espectrales», *Revista de la Real Academia de Ciencias Exactas, Físicas y Naturales*, 80, pp. 177-185.

Mergerson, J. W. (1981): «Crop area estimates using ground gathered and Landsat data: A multitemporal approach», *15th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor, pp. 1211-1218.

Meyer, P.; Itten, K. I.; Kellenbenberger, T.; Sandmeier, S. y Sandmeier, R. (1993): «Radiometric corrections of topographically induced effects on Landsat TM data in an alpine environment», *ISPRS Journal of Photogrammetry and Remote Sensing*, 48, pp. 17-28.

Middelkoop, H. y Janssen, L. L. (1991): «Implementation of temporal relationships in knowledge based classification of satellite images», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 937-945.

Miller, L. D. y Williams, D. L. (1978): «Monitoring forest canopy alteration around the world with digital analysis of Landsat imagery», *International Symposium on Remote Sensing for Observation and Inventory of Earth Resources and the Endangered Environment*, Freiburg, pp. 1721-1763.

Millington, A. C.; Wellens, J.; Settle, J. J. y Saull, R. J. (1994): «Explaining and monitoring land-cover dynamics in drylands using multi-temporal analysis of NOAA-AVHRR imagery», en G. M. Foody y P. J. Curran (eds.), *Environmental Remote Sensing from Regional to Global Scales*, Chichester, John Wiley & Sons, pp. 16-43.

Milton, E. J.; Rollin, E. M. y Emery, D. R. (1995): «Advances in field spectroscopy», en F. M. Danson y S. E. Plummer, *Advances in Environmental Remote Sensing*, Chichester, John Wiley, pp. 9-32.

Milton, N. M.; Collins, W.; Chang, S. H. y Schmidt, R. G. (1983): «Remote detection of metal anomalies on Pilot Mountain», *Economic Geology*, Randolph County, North Carolina, 78, pp. 605-617.

Minnaert, M. (1941): «The reciprocity principle in lunar photometry», *Astrophysics Journal*, 93, pp. 403-410.

Mitas, L. y Mitasova, H. (1999): «Spatial Interpolation», en P. A. Longley, M. F. Goodchild y D. W. Rhind, *Geographical Information Systems*, Nueva York, John Wiley & Sons, Inc.

Moghaddam, M. y Saatchi, S. S. (1999): «Monitoring tree moisture using an estimation algorithm applied to SAR data from BOREAS», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 901-916.

Molina, G. Z. y Chuvieco, E. (1997): «Detección del crecimiento urbano en la ciudad de Maracaibo (Venezuela) mediante análisis multitemporal de imágenes MSS y TM», en J. L. Casanova y J. Sanz, *Teledetección: usos y aplicaciones*, Valladolid, Universidad de Valladolid, pp. 361-368.

Molina, Z. (1998): «Análisis de calidad ambiental de vida para la ciudad de Maracay (Venezuela) usando la teledetección y los S.I.G.», tesis doctoral, Departamento de Geografía, Universidad de Alcalá.

Molina, Z. y Chuvieco, E. (1996): «Evaluación de índices texturales para discriminar morfología urbana: análisis de la ciudad de Maracay (Venezuela)», *Revista de Teledetección*, pp. 49-57.

Molina, Z.; Barredo, J. I.; Díaz, M. A. y Chuvieco, E. (1999): «Propuesta para el análisis de la calidad ambiental de vida urbana en Latinoamérica mediante el empleo de las nuevas tecnologías», *Cooperación Internacional*, 2, pp. 83-102.

Moller-Jensen, L. (1990): «Knowledge-based classification of an urban area using texture and context information in Landsat TM imagery», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 899-904.

Moody, A. y Strahler, A. H. (1994): «Characteristics of composited AVHRR data and problems in their classification», *International Journal of Remote Sensing*, 15, pp. 3473-3491.

Moore, G. K. y Waltz, F. A. (1983): «Objective procedures for lineament enhancement and extraction», *Photogrammetric Engineering and Remote Sensing*, 49, pp. 641-647.

Morain, S. A. y Budge, A. M. (eds.) (1996): «Earth Observing Platforms and Sensors», *Manual of Remote Sensing*, Bethesda, American Society of Photogrammetry and Remote Sensing.

Morain, S. A. y Klankamsorn, B. (1978): «Forest mapping and inventory techniques through visual analysis of Landsat imagery: examples from Thailand», *12th International Symposium on Remote Sensing of Environment*, Ann Arbor, pp. 417-426.

Moran, M. S.; Clarke, T. R.; Inoue, Y. y Vidal, A. (1994): «Estimating crop water deficit using the relation between surface-air temperature and spectral vegetation index», *Remote Sensing of Environment*, 49, pp. 246-263.

Moran, P. (1948): «The interpretation of statistical maps», *Journal of the Royal Statistical Society*, 108, pp. 243-251.

Moreira, J. M. y Fernández-Palacios, A. (1995): *Usos y coberturas vegetales del suelo en Andalucía. Seguimiento a través de imágenes de satélite*, Sevilla, Consejería de Medio Ambiente, Junta de Andalucía.

Moreira, J. M. y Ojeda, J. (1992): *Andalucía, una visión inédita desde el espacio*, Sevilla, Agencia de Medio Ambiente, Junta de Andalucía.

Mouat, D. A., Mattin, G. G. y Lancaster, J. (1993): «Remote sensing techniques in the analysis of change detection», *Geocarto International*, 8, pp. 39-50.

Mounsey, H. M. (1991): «Multisource, multinational environmental G.I.S.: leassons learnt from CORINE», en D. Maguire; M. F. Goodchild y D. W. Rhind (eds.), *Geographical Information Systems*, Londres, Longman, pp. 185-200.

Muchoki, C. H. K. (1988): «Remotely sensed relationships between wooded patch habitats and agricultural landscape type: a basis for ecological planning», en M. R. Moss (ed.), *Landscape ecology and management*, Montreal, Polyscience Publications, pp. 85-95.

Mulders, M. A. (1987): *Remote Sensing in Soil Science*, Amsterdam, Elsevier.

Muller, J. P. (1988*a*): «Computing issues in digital image processing in remote sensing», en J. P. Muller, *Digital Image Processing in Remote Sensing*, Londres, Taylor and Francis, pp. 1-20.

— (ed.) (1988*b*): *Digital Image Processing in Remote Sensing*, Londres, Taylor & Francis.

Munechika, C. K.; Warnick, J. S.; Salvaggio, C. y Schott, J. R. (1993): «Resolution enhancement of multispectral image data to improve classification accuracy», *Photogrammetric Engineering and Remote Sensing*, 59, pp. 67-72.

Murphy, D. L. (1985): «Estimating neighborhood variability with a binary comparison matrix», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 667-674.

Murtha, P. A. (1978): «Remote sensing and vegetation damage: a theory for detection and assessment», *Photogrammetric Engineering and Remote Sensing*, 44, pp. 1147-1158.

Musick, H. B. y Grover, H. D. (1991): «Image textural measures as indices of landscape pattern», en M. G. Turner y R. H. Gardner, *Quantitative Methods in Landscape Ecology*, Nueva York, Springer-Verlag, pp. 77-103.

Mussakowski, R. S. (1985): «Revising agricultural land use maps by digital change detection on Landsat data», *ASPRS 51st Annual Meeting*, Washington, pp. 312-319.

Myneni, R. B. y Asrar, G. (1994): «Atmospheric effects and spectral vegetation indices», *Remote Sensing of Environment*, 47, pp. 390-402.

Myneni, R. B.; Hall, F. G.; Sellers, P. J. y Marshak, A. L. (1995): «The interpretation of spectral vegetation indexes», *IEEE Transactions on Geoscience and Remote Sensing*, 33.

NASA (1976): *Mission to Earth. Landsat Views of the World*, Greenbelt, Goodard Space Flight Center, SP 360.

— (1977): *Skylab Explores the Earth*, Washington, NASA, SP 380.

National Audubon Society (1995): *Earth from Space*, Nueva York, Alfred A. Knopf.

National Geographic (1999): *Satellite Atlas of the World*, Washington, D.C., National Geographic Society.

Ne'eman, G.; Fotheringham, C. J. y Keely, J. E. (1999): «Patch to landscape patterns in post fire recruitment of a serotinous conifer», *Plant Ecology*, 145, pp. 235-242.

Nelson, B. W. (1994): «Natural forest disturbance and change in the Brazilian Amazon», *Remote Sensing Reviews*, 10, pp. 105-125.

Nelson, R. y Grebowsky, G. (1982): «Evaluation of temporal registration of Landsat scenes», *International Journal of Remote Sensing*, 3, pp. 45-50.

Nemani, R. R.; Pierce, L.; Running, S. W. y Edward, S. (1993): «Developing satellite-derived estimates of surface moisture status», *Journal of Applied Meteorology*, 32, pp. 548-557.

Nikolaus, S. (1988): «Visual and digital classification of Landsat TM data for soil, physiography and land use mapping in Axios alluvial plain, Thessaloniki, Greece», *Geocarto International*, 4, pp. 55-66.

Novak, K. (1992): «Rectification of digital imagery», *Photogrammetric Engineering and Remote Sensing*, 58, pp. 339-344.

Núñez, R. (1976): *Thematic Mapping, Land Use, Geological Structure and Water Resources in Central Spain*, Madrid, NASA Project - Instituto Geográfico Nacional.

Núñez, R.; Chuvieco, E.; Sancho, J.; Palou, F. y Casas, J. M. (1983): «Mapa de usos del suelo de la región central. Estudio piloto sobre la aplicación del tratamiento digital de imágenes Landsat a la confección de mapas de usos del suelo», *Geographica*, 25, pp. 61-78.

O'Connell, K. M. y Lachman, B. E. (2001): «From space imagery to information: commercial remote sensing market factors and trends», en J. C. Baker, K. M. O'Connell y R. A. Williamson, *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 53-78.

O'Connell, K. M. y Hilgenberg, G. (2001): «U.S. Remote Sensing programs and policies», en J. C. Baker, K. M. O'Connell y R. A. Williamson, *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 139-163.

Olorunfemi, J. F. (1987): «Identification and measurement of the areal extent settlements from Landsat», *International Journal of Remote Sensing*, 8, pp. 1839-1843.

O'Neill, R. V.; Krummel, J. R.; Gardner, R. H.; Sugihara, G. y Jackson, B. (1988): «Indices of landscape pattern», *Landscape Ecology*, 1, pp. 153-162.

Ortí, F.; García, A. y Martín, M. A. (1979): «Geometric correction of MSS Landsat images using a ground control point library», en J. Allan y R. Harris (eds.), *Remote Sensing and National Mapping*, Londres, Remote Sensing Society, pp. 17-26.

O.T.A. (1984): «Remote Sensing and the Private Sector: Issues for Discussion», *A Technical Memorandum*, Washington, D.C., U.S. Congress, Office of Technology Assessment, OTA-TM-ISC-20.

— (1994): *Remotely Sensed Data: Technology, Management and Markets*, Washington, D.C., U.S. Government Printing Office - U.S. Congress, Office of Technology Assessment, OTA-ISS-604.

Ouaidrari, H. y Vermote, E. F. (1999): «Operational Atmospheric Correction of Landsat TM Data», *Remote Sensing of Environment*, 70, pp. 4-15.

Palà, V. y Pons, X. (1995): «Incorporation of relief in polynomial-based geometric corrections», *Photogrammetric Engineering and Remote Sensing*, 61, pp. 935-944.

Palacios-Orueta, A. y Ustin, S. L. (1996): «Multivariate statistical classification of soil spectra», *Remote Sensing of Environment*, 57, pp. 108-118.

— (1998): «Remote sensing of soil properties in the Santa Monica Mountains. Spectral Analysis», *Remote Sensing of Environment*, 65, pp. 170-183.

Palacios-Orueta, A.; Pinzon, J. E.; Ustin, S. L. y Roberts, D. A. (1999): «Remote sensing of soil properties in the Santa Monica Mountains. Hierarchical Foreground and Background Analysis», *Remote Sensing of Environment*, 68, pp. 138-151.

Paloscia, S. (1994): «Microwave emission from vegetation», en B. J. Choudhury, Y. H. Kerr, E. G. Njoku y P. Pampaloni, *Passive Microwave Remote Sensing of Land-Atmosphere Interactions*, Utrecht, VSP BV, pp. 357-374.

Paloscia, S. y Pampoloni, P. (1984): «Microwave remote sensing of plant water stress», *Remote Sensing of Environment*, 16, pp. 249-255.

Paltridge, G. W. y Barber, J. (1988): «Monitoring grassland dryness and fire potential in Australia with NOAA/AVHRR data», *Remote Sensing of Environment*, 25, pp. 381-394.

Parry, J. T. (1986): «Background, perspective, and issues for remote sensing in the Tropics», en M. J. Eden y J. T. Parry, *Remote Sensing and Tropical Land Management*, Nueva York, John Wiley & Sons Ltd., pp. 337-360.

Pastor, J. y Broshart, M. (1990): «The spatial pattern of a Northern conifer-hardwood landscape», *Landscape Ecology*, 4, pp. 55-68.

Pattillo, C. y Pezoa, M. E. (2000): «Interferometría y coherencia multitemporal aplicadas a la identificación de Glaciares», *IX Simposio Latinoamericano de Percepción Remota*, Iguazú.

Pellemans, A. H.; Jordans, R. W. y Allewijn R. (1993): «Merging multispectral and pancromatic SPOT images with respect to the radiometric properties of the sensor», *Photogrammetric Engineering and Remote Sensing*, 59, pp. 81-87.

Pereira, J. M.; Sa, A. C. L.; Sousa, A. M. O.; Martín, M. P. y Chuvieco, E. (1999): «Regional-scale burnt area mapping in Southern Europe using NOAA-AVHRR 1 km data», en E. Chuvieco (ed.), *Remote Sensing of Large Wildfires in the European Mediterranean Basin*, Berlín, Springer-Verlag, pp. 139-155.

Pereira, J. M. C. (1999): «A comparative evaluation of NOAA-AVHRR vegetation indices for burned surface detection and mapping», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 217-226.

Pereira, J. M. C. y Govaerts, Y. (2001): *Potential Fire Applications from MSG/SEVIRI Observations*, Darmstadt, Eumetsat, Programme Development Department Technical Memorandum No. 7.

Pereira, J. M. C.; Chuvieco, E.; Beudoin, A. y Desbois, N. (1997): «Remote Sensing of burned areas: a review», en E. Chuvieco (ed.), *A review of remote sensing methods for the study of large wildland fires*, Alcalá de Henares, Departamento de Geografía, Universidad de Alcalá, pp. 127-184.

Perry, C. R. y Lautenschlager, L. F. (1984): «Functional equivalence of spectral vegetation indices», *Remote Sensing of Environment*, 14, pp. 169-182.

Peters, A.; Rundquist, D. C. y Wilhite, P. A. (1991): «Satellite detection of the geographic core of the 1988 Nebraska drought», *Agricultural and Forest Meteorology*, 57, pp. 35-47.

Pickup, G. y Foran, B. D. (1987): «The use of spectral and spatial variability to monitor cover change on inert landscapes», *Remote Sensing of Environment*, 23, pp. 351-363.

Pilon, P.; Howarth, P. J.; Bullock, R. A. y Adeniyi, P. O. (1988): «An enhanced classification

approach to change detection in semi-arid environments», *Photogrammetric Engineering and Remote Sensing*, 54, pp. 1709-1716.
Pinilla, C. (1995): *Elementos de Teledetección Espacial*, Madrid, RA-MA.
Pinilla, C.; Alcalá, A. y Ariza, F. J. (1997): «Filtrado de imágenes en el dominio de la frecuencia», *Revista Española de Teledetección*, 8, pp. 47-52.
Pinty, B. y Verstraete, M. M. (1992): «GEMI: a non-linear index to monitor global vegetation from satellites», *Vegetatio*, 101, pp. 15-20.
Pinzón, J. E.; Ustin, S. L.; Castañeda, C. M. y Smith, M. O. (1998): «Investigation of Leaf biochemistry by Hierarchical Foreground/Background Analysis», *IEEE Transactions on Geoscience and Remote Sensing*, 36, pp. 1913-1927.
Podwysocki, M. H.; Power, M. S. y Jones, O. D. (1985): «Preliminary evaluation of the Landsat-4 Thematic Mapper data for mineral exploration», en S. G. Ungar (ed.), *The Earth's Surface Studied from Space. Advances in Space Research*, Oxford, Pergamon Press, pp. 13-20.
Pons, X. y Solé-Sugrañes, L. (1994): «A Simple Radiometric Correction Model to Improve Automatic Mapping of Vegetation from Multispectral Satellite Data», *Remote Sensing of Environment*, 48, pp. 191-204.
Potter, C. S. y Brooks, V. (2000): «Global analysis of empirical relations between annual climate and seasonality of NDVI», *International Journal of Remote Sensing*, 19, pp. 2921-2948.
Prados, M. J. (1995): «La utilización de imágenes Landsat-5 TM para la estimación y seguimiento de áreas de monocultivo arrocero y su vinculación a espacios naturales», *Revista de Teledetección*, 5, pp. 44-48.
Privette, J. L.; Fowler, C.; Wick, G. A.; Baldwin, D. y Emery, W. J. (1995): «Effects of orbital drift on Advanced Very High Resolution Radiometer products: Normalized Difference Vegetation Index and Sea Surface Temperature», *Remote Sensing of Environment*, 53, pp. 164-171.
Quarmby, N. A.; Townshend, J. R. G.; Settle, J. J.; White, K. H.; Milnes, M.; Hindle, T. L. y Silleos, N. (1992): «Linear mixture modelling applied to AVHRR data for crop area estimation», *International Journal of Remote Sensing*, 13, pp. 415-425.
Quattrochi, D. A. y Goodchild, M. F. (eds.) (1997): *Scale in Remote Sensing and GIS*, Boca Raton, CRC Press, Inc.
Quegan, S. (1995): «Recent advances in understanding SAR imagery», en F. M. Danson y S. E. Plummer, *Advances in Environment Remote Sensing*, Chichester, John Wiley & Sons, pp. 89-104.
Rebollo, M. y Orti, F. (1980): *Pattern Recognition Techniques: Remote Sensing Applications at Centro de Investigación UAM-IBM*, Madrid, Centro de Investigación UAM-IBM.
Rees, G. (1999): *The Remote Sensing Data Book*, Cambridge, Cambridge University Press.
Reinhardt, E. D. y Ringleb, R. V. (1990): «Analysis of changes in patterns of a forested landscape following wildfire using Landsat data and landscape ecology methodology», *Resource Technollogy 90*, Washington, D.C., American Society of Photogrammetry and Remote Sensing, pp. 83-93.
Rencz, A. y Ryerson, R. A. (eds.) (1999): «Remote Sensing for the Earth Sciences», *Manual of Remote Sensing*, Nueva York, John Wiley & Sons.
Renz, A. N. (1985): «Multitemporal analysis of Landsat imagery for monitoring forest cutovers in Nova Scotia», *Canadian Journal of Remote Sensing*, 11, pp. 189-194.
Rhind, D. y Clark, P. (1988): «Cartographic data inputs to global databases», en H. Mounsey, *Building Databases for Global Science*, Londres, Taylor and Francis, pp. 79-104.
Riaño, D. (2000): *Cartografía de modelos de combustible con teledetección*, Trabajo de investigación, Departamento de Ecología, Universidad de Alcalá de Henares.

Riaño, D.; Salas, J. y Chuvieco, E. (2001*a*): «Cartografía de modelos de combustible con teledetección: aportaciones a un desarrollo ambiental sostenible», *Estudios Geográficos*, 62, pp. 309-333.
Riaño, D.; Vaughan, P. y Chuvieco, E. (2000): «Bases para estimar el contenido de humedad en plantas mediterráneas a partir de la teledetección», *Mediterránea. Serie de estudios biológicos*. Época II, pp. 27-34.
Riaño, D.; Chuvieco, E.; Ustin, S. L.; Zomer, R.; Dennison, P.; Roberts, D. y Salas, J. (2001*b*): «Assessment of vegetation regeneration after fire through multitemporal analysis of AVIRIS images in the Santa Monica Mountains», *Remote Sensing of Environment*, 79, pp. 60-71.
Richards, J. A. (1993): *Remote Sensing Digital Image Analysis. An Introduction*, 2.ª edición, Berlín, Springer-Verlag.
Richards, J. A. y Xia, X. (1999): *Remote Sensing Digital Image Analysis. An Introduction*, 3.ª edición, Berlín, Springer-Verlag.
Richter, R. (1996): «Atmospheric correction of satellite data wih haze removal including a haze/clear transition region», *Computers and Geosciences*, 22, pp. 675-681.
— (1997): «Correction of atmospheric and topographic effects for high spatial resolution satellite imagery», *International Journal of Remote Sensing*, 18, pp. 1099-1111.
Ricotta, C. y Retzlaff, R. (2000): «Self-similar spatial clustering of wildland fires: the example of a large wildfire in Spain», *International Journal of Remote Sensing*, 21, pp. 2113-2118.
Ricotta, C.; Avena, G. C.; Olsen, E. R.; Ramsey, R. D. y Winn, D. S. (1998): «Monitoring the landscape stability of the Mediterranean vegetation in relation to fire with a fractal algorithm», *International Journal of Remote Sensing*, 19, pp. 871-881.
Riitters, K. H.; O'Neill, R. V.; Hunsaker, C. T.; Wickham, J. D.; Yankee, D. H. y Timmins, S. P. (1995): «A factor analysis of landscape pattern and structure metrics», *Landscape Ecology*, 10, pp. 23-39.
Ripple, W. J.; Bradshaw, G. A. y Spies, T. A. (1991): «Measuring forest landscape patterns in the cascade range of Oregon», *Biological Conservation*, 57, pp. 73-88.
Roberts, D.; Smith, G. M. y Adams, M. L. (1993): «Green Vegetation, Non photosinthetic vegetation and soils in AVIRIS data», *Remote Sensing of Environment*, 44, pp. 255-269.
Roberts, D.; Gardner, M.; Regelbrugge, J.; Pedreros, D. y Ustin, S. (1997*a*): «Mapping the distribution of Wildfire fuels using AVIRIS in the Santa Monica Mountains», *Summaries of the Seventh JPL Airbone Earth Science Workshop*, Pasadena, California, Jet Propulsion Laboratory, pp. 345-352.
Roberts, D. A.; Green, R. O. y Adams, J. B. (1997*b*): «Temporal and spatial patterns in vegetation and atmospheric properties from AVIRIS», *Remote Sensing of Environment*, 62, pp. 223-240.
Roberts, D. A.; Gardner, M.; Church, R.; Ustin, S.; Scheer, G. y Green, R. O. (1998): «Mapping chaparral in the Santa Monica Mountains using multiple endmembers spectral mixture models», *Remote Sensing of Environment*, 65, pp. 267-279.
Robin, M. (1998): *La Télédétection*, París, Nathan.
Robinove, C. (1981): «The logic of multispectral classification and mapping the land», *Remote Sensing of Environment*, 11, pp. 231-244.
Robinson, G. D.; Gross, H. N. y Schott, J. R. (2000): «Evaluation of Two Applications of Spectral Mixing Models to Image Fusion», *Remote Sensing of Environment*, 71, pp. 272-281.
Robinson, I. S. (1985): *Satellite Oceanography. An Introduction for Oceanographers and Remote Sensing Scientist*, Chichester, John Wiley.
Rock, B. N.; Moshizaki, T. y Miller, J. R. (1988): «Comparison of in situ and airborne spectral measurements of the blue shift associated with forest decline», *Remote Sensing of Environment*, 24, pp. 109-127.

Rosborough, G. W.; Baldwin, D. y Emery, W. J. (1994): «Precise AVHRR image navigation», *IEEE Transactions on Geoscience and Remote Sensing*, 32, pp. 644-657.

Rosenfeld, G. H. (1982): «Sample design for estimating change in land use and land cover», *Photogrammetric Engineering & Remote Sensing*, 48, pp. 793-801.

Rosenfeld, G. H.; Fitzpatrick-Lins, K. y Ling, H. S. (1982): «Sampling for thematic map accuracy testing», *Photogrammetric Engineering and Remote Sensing*, 48, pp. 131-137.

Roy, D. (2000): «The impact of misregistration upon composited wide field of view satellite data and implications for change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 38, pp. 2017-2032.

Roy, P. S. y Tomar, S. (2000): «Biodiversity characterization at landscape level using geospatial modelling technique», *Biological Conservation*, 95, pp. 95-109.

Ruiz, G. (1992): *Imagen de Venezuela. Una visión espacial*, Caracas, Petróleos de Venezuela.

Ruiz, L. A. (1994): *Introducción al tratamiento digital de imágenes*, Valencia, Universidad Politécnica, Servicio de Publicaciones.

Ruiz-Verdú, A.; Domínguez, J. A. y Peña, R. (2001): «Teledetección aeroportada hiperespectral del embalse de Ribarroja», en J. I. Rosell y J. A. Martínez-Casasnovas (eds.), *Teledetección. Medio ambiente y Cambio Global*, Lleida, Universitat de Lleida y Editorial Milenio, pp. 318-321.

Rumelhart, D. E.; Hinton, G. E. y Williams, R. J. (1986): «Learning representations by back-propagating errors», *Nature*, 323, pp. 533-535.

Sadar, S. A.; Linden, D. S. y McGuire, M. (1982): «Fuels mapping from Landsat imagery and digital terrain data for fire supression decisions», *ACSM-ASP Congress*, Fort Lauderdale, pp. 345-351.

Sader, S. A. y Winne, J. C. (1992): «RGB-NDVI colour composites for visualizing forest change dynamics», *International Journal of Remote Sensing*, 13, pp. 3055-3067.

Sagdejew, R. S. (1982): *Atlas Zur Interpretation Aerokosmischer Multispektralaufnahmen*, Berlín, Akademie Verlag y Mosku Verlag Nauka.

Salas, F. J. y Chuvieco, E. (1994): «Sistemas de Información Geográfica y Teledetección en la prevención de incendios forestales: un ensayo en el Macizo Oriental de la Sierra de Gredos», *Estudios Geográficos*, 40, pp. 683-710.

— (1995): «Aplicación de imágenes Landsat-TM a la cartografía de modelos combustibles», *Revista de Teledetección*, 5, pp. 18-28.

Salisbury, J. W. y D'aria, D. M. (1992): «Emissivity of terrestrial materials in the 8-14 μm atmospheric window», *Remote Sensing of Environment*, 42, pp. 83-106.

— (1994): «Emissivity of terrestrial materials in the 3-5 μm atmospheric window», *Remote Sensing of Environment*, 47, pp. 345-361.

Sample, V. A. (ed.) (1994): *Remote Sensing and GIS in Ecosystem management*, Washington, D.C., The Island Press.

Sánchez, M. I. (1992): *Métodos para el estudio de la evaporación y evapotranspiración*, Logroño, Cuadernos Técnicos de la Sociedad Española de Geomorfología, Geoforma Ediciones.

Sánchez, M. I. y Chuvieco, E. (2000): «Estimación de evapotranspiración del cultivo de referencia, ETo, a partir de imágenes NOAA-AVHRR», *Revista Española de Teledetección*, 14, pp. 11-21.

Sancho, J. (1992): «Imagen y Paisaje», en I.G.N. (ed.), *Atlas Nacional de España*, Madrid, Instituto Geográfico Nacional, Sección I, Grupo 3c.

Sancho, J. y Chuvieco, E. (1986): *Castellón desde el Espacio*, Castellón, Caja de Ahorros de Castellón de la Plana.

— (eds.) (1992): *Iberoamérica desde el Espacio*, Madrid, Lunwerg - Sociedad Estatal Quinto Centenario - CNIG - Universidad de Alcalá.

Sancho, J.; Bosque, J.; Chuvieco, E. y Puyol, R. (1993): «II. Información Geográfica y Representación Cartográfica», *Geografía General I*, Madrid, Taurus, pp. 24-72.

Sandmeier, S. R. y Deering, D. W. (1999): «Structure Analysis and Classification of Boreal Forests Using Airborne Hyperspectral BRDF Data from ASAS», *Remote Sensing of Environment*, 69, pp. 281-295.

Sandmeier, S. R. e Itten, K. I. (1999): «A Field Goniometer System (FIGOS) for Acquisition of Hyperspectral BRDF data», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 978-986.

Saunders, R. W. y Kriebel, K. T. (1988): «An improved method for detecting clear sky and cloudy radiances from AVHRR data», *International Journal of Remote Sensing*, 9, pp. 123-150.

Saura, S. (2002): «Influencia de la escala en la configuración del paisaje: estudio mediante un nuevo método de simulación espacial, imágenes de satélite y cartografías temáticas», tesis doctoral, E.T.S.I. Montes, Universidad Politécnica de Madrid.

Saura, S. y Martínez Millán, F. J. (2001): «Sensitivity of landscape pattern metrics to map spatial extent», *Photogrammetric Engineering and Remote Sensing*, 67, pp. 1027-1036.

Saura, S. y San Miguel, J. (2001): «Cartografía de zonas forestales en España mediante imágenes IRS-WIFS y árboles de clasificación», en J. I. Rosell y J. A. Martínez-Casasnovas, (eds.), *Teledetección. Medioambiente y Cambio Global*, Lleida, Universitat de Lleida y Editorial Milenio, pp. 151-154.

Schanda, E. (ed.) (1976): *Remote Sensing for Environment Sciences*, Nueva York, Springer-Verlag.

Schiewe, J.; Tufte, L. y Ehlers, M. (2001): «Potential and problems of multi-scale segmentation methods in remote sensing», *GIS*, 06, pp. 34-39.

Schneider, S. (1980): «Interpretation of satellite imagery for determination of land use data», *International Journal of Remote Sensing*, 1, pp. 85-90.

Schowengerdt, R. A. (1983): *Techniques for Image Processing and Classification in Remote Sensing*, Nueva York, Academic Press.

— (1997): *Remote Sensing. Models and methods for image processing*, 2.ª edición, San Diego, California, Academic Press.

Schowengerdt, R. A. y Wang, H. L. (1989): «A general purpose expert system for image processing», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 1277-1284.

Schriever, J. R. y Congalton, R. G. (1995): «Evaluating seasonal variability as an aid to cover-type mapping from Landsat Thematic Mapper data in the Northeast», *Photogrammetric Engineering and Remote Sensing*, 61, pp. 321-327.

Schroeder, M. (1986): «Spacelab Metric Camera Experiments», en K. H. Szekielda (ed.), *Satellite Remote Sensing for Resources Development*, Londres, Graham and Trotman Ltd., pp. 81-92.

Scott, J. C. (ed.) (1997): *Report on Earth Observation, Hazard Analysis and Communications Technology for Early Warning*, United Nations International Decade for Natural Disaster Reduction IDNDR Early Warning Programme, Geneva, IDNDR Secretariat.

Sellers, P. J. (1987): «Canopy reflectance, photosynthesis and transpiration. II. The role of biophysics in the linearity of their interdependence», *Remote Sensing of Environment*, 21, pp. 143-183.

— (1989): «Vegetation-Canopy Spectral reflectance and Biophysical Processes», en G. Asrar (ed.), *Theory and Applications of Optical Remote Sensing*, Nueva York, Wiley, pp. 297-335.

Settle, J. J. y Drake, N. A. (1993): «Linear mixing and the estimation of ground cover proportions», *International Journal of Remote Sensing*, 14, pp. 1159-1177.

Shaw, G. y Wheeler, D. (1985): *Statistical Techniques in Geographical Analysis*, Chichester, Wiley.

Sheffield, C. (1981): *Earth Watch. A Survey of the World from Space*, Londres, Sidgwick and Jackson Ltd.
— (1983): *Man on Earth. The Marks of Man. A Survey from Space*, Londres, Sidgwick and Jackson Ltd.
— (1985): «Selecting band combinations from multispectral data», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 681-687.
Shepherd, J. D. y Dymond, J. R. (2000): «BRDF Correction of Vegetation in AVHRR Imagery», *Remote Sensing of Environment*, 74, pp. 397-408.
Shimabukuro, Y. E. y Smith, J. A. (1991): «The Least-Squares Mixing Models to Generate Fraction Images Derived from Remote Sensing Multispectral Data», *IEEE Transactions on Geosciences and Remote Sensing*, 29, pp. 16-20.
Shimabukuro, Y. E.; Holben, B. N. y Tucker, C. J. (1994): «Fraction images derived from NOAA-AVHRR data for studying the deforestation in the Brazilian Amazon», *International Journal of Remote Sensing*, 15, pp. 517-520.
Short, N. M. (1982): *The Landsat Tutorial Workbook: Basics of Satellite Remote Sensing*, Washington, D.C., NASA Scientific and Technical Information Branch.
— (2001): «The Remote Sensing Tutorial (An Online Handbook)», Applied Information Sciences Branch. NASA's Goddard Space Flight Center (http://rst.gsfc.nasa.gov).
Short, N. M. y Blair, R. W. (eds.) (1986): *Geomorphology from Space*, Washington, D.C., NASA, Scientific and Technical Information Branch.
Short, N. M. y Stuart, L. M. (1982): *The Heat Capacity Mapping Mission (HCMM) Anthology*, Washington, D.C., NASA Scientific and Technical Information Branch.
Siljeström, P. y Moreno, A. (1995): «Monitoring burnt areas by principal components analysis of multi-temporal TM data», *International Journal of Remote Sensing*, 16, pp. 1577-1587.
Simpson, J. J. y Gobat, J. I. (1996): «Improved Cloud Detection for Daytime AVHRR Scenes over Land», *Remote Sensing of Environment*, 55, pp. 21-49.
Singh, A. (1986): «Change detection in the tropical forest environment of Northeastern India using Landsat», en M. J. Eden y J. T. Parry (eds.), *Remote Sensing and Tropical Land Management*, Chichester, John Wiley, pp. 237-254.
Skidmore, A. K. (1989): «An expert system classifies eucalypt forest types using Thematic Mapper data and digital terrain model», *Photogrammetric Engineering and Remote Sensing*, 55, pp. 1149-1464.
Skole, D. y Tucker, C. (1993): «Tropical deforestation and habitat fragmentation in the Amazon. Satellite data from 1978 to 1988», *Science*, 260, pp. 1905-1910.
Slater, P. N. (1980): *Remote Sensing, Optics and Optical Systems*, Reading, MA, Addison-Wesley Pub. Co.
Slavik, B. (1974): *Methods for Studying Plant Water Relations*, Prague, Czechoslovak Academy of Sciences-Springer Verlag.
Smith, J. L. y Kovalick, B. (1985): «A comparison of the effects of resampling before and after classification on the accuracy of a Landsat derived cover type map», *Advances Techniques for Monitoring Global Environmental Data*, Londres, pp. 391-399.
Smith, M. O.; Ustin, S. L.; Adams, J. B. y Gillespie, A. R. (1990*a*): «Vegetation in deserts: I. A regional measure of abundance from multispectral images», *Remote Sensing of Environment*, 31, pp. 1-26.
— (1990*b*): «Vegetation in deserts: II. Environmental influences on regional vegetation», *Remote Sensing of Environment*, 31, pp. 27-52.
Smith, R. M. (1984): *Images of the World. An Atlas of Satellite Imagery and Maps*, Essex, Collins-Longman.
Smits, P. y Annoni, A. (1999): «Updating land-cover maps by using texture information from very high-resolution space-borne imagery», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 1244-1254.
— (2000): «Toward specification-driven change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 38, pp. 1484-1488.
Snedecor, G. W. y Cochran, W. G. (1980): *Statistical Methods*, 7.ª edición, Ames, The Iowa University Press.
Sobrino, J. A. (ed.) (2000): *Teledetección*, Valencia, Servicio de Publicaciones, Universidad de Valencia.
Srinivasan, A. y Richards, J. A. (1990): «Knowledge-based techniques for multi-source classification», *International Journal of Remote Sensing*, 11, pp. 505-525.
Star, J. L. y Estes, J. E. (1990): *Geographic Information Systems*, Englewood Cliffs, Prentice Hall.
Star, J. L.; Estes, J. E. y Davis, F. (1991): «Improved integration of remote sensing and Geographic Information Systems: a background to NCGIA initiative 12», *Photogrammetric Engineering and Remote Sensing*, 57, pp. 643-645.
Stehman, S. V. (1992): «Comparison of systematic and random sampling for estimating the accuracy of maps generated from remotely sensed data», *Photogrammetric Engineering and Remote Sensing*, 58, pp. 1343-1350.
— (1999*a*): «Comparing thematic maps based on map value», *International Journal of Remote Sensing*, 20, pp. 2347-2366.
— (1999*b*): «Basic probability sampling designs for thematic map accuracy assessment», *International Journal of Remote Sensing*, 20, pp. 2423-2441.
Steven, M. D. y Jaggard, K. W. (1995): «Advances in crop monitoring by remote sensing», en F. M. Danson y S. E. Plummer (eds.), *Advances in Environmental Remote Sensing*, Chichester, John Wiley & Sons, pp. 143-156.
Story, M. y Congalton, R. G. (1986): «Accuracy assessment: A user's perspective», *Photogrammetric Engineering and Remote Sensing*, 52, pp. 397-399.
Story, M. H. y Campbell, J. B. (1986): «The effect of training data on classification accuracy», *ACSM-ASPRS Convention. Technical Papers*, pp. 370-379.
Strahler, A. H. (1980): «The use of prior probabilities in maximun likelihood classification of remotely sensed data», *Remote Sensing of Environment*, 10, pp. 135-163.
— (1981): «Stratification of natural vegetation for forest and rangeland inventory using Landsat digital imagery and collateral data», *International Journal of Remote Sensing*, 2, pp. 15-41.
— (1984): «Timber inventory using Landsat», *8th Canadian Symposium on Remote Sensing*, Quebec, pp. 665-674.
Strahler, A. H.; Logan, T. L. y Bryant, N. A. (1978): «Improving forest cover classification accuracy from Landsat by incorporating topographic information», *12th International Symposium on Remote Sensing of Environment*, Ann Arbor, MI, pp. 927-941.
Strahler, A. H.; Woodcock, C. E. y Smith, J. A. (1986): «On the nature of models in remote sensing», *Remote Sensing of Environment*, 20, pp. 121-140.
Strain, P. y Engle, F. (1993): *Looking at Earth*, Atlanta, Turner Publishing Inc.
Swain, P. H. y Davis, S. M. (eds.) (1978): *Remote Sensing: The Quantitative Approach*, Nueva York, McGraw-Hill.
Szekielda, K. H. (1988): *Satellite Monitoring of the Earth*, Nueva York, John Wiley & Sons.
Tameishi, H. (1991): «Fisheries detection using NOAA satellite», en S. Murai (ed.), *Applications of Remote Sensing in Asia and Oceania*, Hong Kong, Asian Association on Remote Sensing, pp. 323-332.
Tanre, D.; Deroo, C.; Duhaut, P.; Herman, M.; Morcrette, J. J.; Perbos, J. y Deschamps, P. Y. (1986): *Simulation of the Satellite Signal in the Solar Spectrum (5S)*, Villeneuve d'Asq

(France), Laboratoire d'Optique Atmosphérique, Université des Sciences et Techniques, Lille.

Tapia, L. (1989): «Derecho espacial y programas de observación de la Tierra», en R. Núñez (ed.), *La Observación de la Tierra desde el Espacio*, Santander, Univ. Menéndez Pelayo, pp. 1-15.

Tapiador, F. J. y Casanova, J. L. (2001): «La fusión de datos en teledetección», *Revista Española de Teledetección*, 15, pp. 5-12.

Tateishi, R. y Kajiwara, K. (1991): «Land cover monitoring in Asia by NOAA GVI data» *Geocarto International*, 4, pp. 53-64.

Taylor, B. F.; Dini, P. W. y Kidson, J. W. (1985): «Determination of seasonal and interannual variation in New Zealand pasture growth from NOAA-7 data», *Remote Sensing of Environment*, 18, pp. 177-192.

Teillet, P. M.; Guindon, B. y Goodeonugh, D. G. (1982): «On the slope-aspect correction of multispectral scanner data», *Canadian Journal of Remote Sensing*, 8, pp. 84-106.

Teng, W. L. (1990): «AVHRR monitoring of U.S. crops during the 1988 drought», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 1143-1146.

Terhalle, U. y Bodechtel, J. (1986): «Landsat TM data enhancement technique for mapping arid geomorphic features», *ISPRS/RSS Symp. Mapping from Modern Imagery*, Edinburgh, Remote Sensing Society, pp. 725-729.

Thomas, I. L. (1980): «Spatial post-processing of spectrally-classified Landsat data», *Photogrammetric Engineering and Remote Sensing*, 46, pp. 1201-1206.

Thomas, I. L.; Benning, V. M. y Ching, N. P. (1987*a*): *Classification of Remotely Sensed Images*, Bristol, Adam Hilger.

Thomas, I. L.; Ching, N. P.; Benning, V. M. y D'Aguanno, J. A. (1987*b*): «A review of multichannel indices of class separability», *International Journal of Remote Sensing*, 8, pp. 331-350.

Tian, Q. y Tong, Q. (2001): «Spectroscopic determination of wheat water status using 1650-1850 nm spectral absorption features», *International Journal of Remote Sensing*, 22, pp. 2329-2338.

Tindal, M. A. (1978): *Educator's Guide for Mission to Earth: Landsat Views the World*, Greenbelt, Maryland, NASA, Goddard Space Flight Center.

Todd, W. J.; Gehring, D. G. y Haman, J. F. (1980): «Landsat wildland mapping accuracy», *Photogrammetric Engineering and Remote Sensing*, 46, pp. 509-520.

Togliatti, G. (1986): «LFC: The second generation photogrammetric camera for space photography», *ESA/EaRSEL Symposium on Europe from Space*.

Toll, D. L. (1984): «An evaluation of simulated Thematic Mapper data and Landsat MSS data for discriminating suburban and regional land use and land cover», *Photogrammetric Engineering and Remote Sensing*, 50, pp. 1713-1724.

Tomlin, D. (1990): *Geographic Information Systems and Cartographic Modeling*, Englewood Cliffs, Prentice Hall.

Tompkins, S.; Mustard, J. F.; Pieters, C. M. y Forsythe, D. W. (1997): «Optimization of end members for spectral mixture analysis», *Remote Sensing of Environment*, 59, pp. 472-489.

Toutin, T. y Beaudoin, M. (1995): «Real-time extraction of planimetric and altimetric features from digital stereo SPOT data using a digital video plotter», *Photogrammetric Engineering and Remote Sensing*, 61, pp. 63-68.

Toutin, T.; Redmond, A.; Hoeppner, E.; Hoja, D. y King, C. (1998): «Radarsat and DEM Data Fusion for 3D Visualization over the Reunion Island for Geoscientific Applications», *Fusion of Earth Data: merging point measurements, raster map and remotely sensed images*, Antipolis, France, pp. 75-84.

Townshend, J. y Justice, C. (1981): «Information extraction from remotely sensed data. A user view», *International Journal of Remote Sensing*, 2, pp. 313-329.

Townshend, J.; Justice, C.; Li, W.; Gurney, C. y McManus, J. (1991): «Global land cover classification by remote sensing: present capabilities and future possibilities», *Remote Sensing of Environment*, 35, pp. 243-255.

Townshend, J. R. G. (1980): *The spatial resolving power of Earth resources satellites: a review*, Maryland, NASA, Goddard Spaceflight Center, Tech. Memorandum 82020.

— (ed.) (1981): *Terrain Analysis and Remote Sensing*, Londres, George Allen and Unwin Ltd.

Townshend, J. R. G.; Justice, C. O.; Gurney, C. y McManus, J. (1992): «The impact of misregistration on change detection», *IEEE Transactions on Geoscience and Remote Sensing*, 30, pp. 1054-1060.

Trevett, J. W. (1986): *Imaging Radar for Resources Surveys*, Londres, Chapman and Hall.

Tricart, J. (1981): «Géomorphologie et quaternaire d'apres une image R.B.V.: La vallee du Sénégal entre Bogué et Podor (Senegal, Mauritanie)», *Annales de Géographie*, 90, pp. 284-310.

Trigg, S. y Flasse, S. (2001): «An evaluation of different bi-spectral spaces for discriminating burned shrub-savannah», *International Journal of Remote Sensing*, 22, pp. 2641-2647.

Trolier, L. J. y Philipson, W. R. (1986): «Visual analysis of Landsat Thematic Mapper images for hydrologic land use and cover», *Photogrammetric Engineering and Remote Sensing*, 52, pp. 1531-1538.

Tsuchiya, K.; Arai, K. y Igarashi, T. (1987): «Marine observation satellite», *Remote Sensing Reviews*, 3, pp. 59-103.

Tucker, C. J. (1979): «Red and photographic infrared linear combinations for monitoring vegetation», *Remote Sensing of Environment*, 8, pp. 127-150.

Tucker, C. J.; Townshend, J. R. G. y Goff, T. E. (1985): «African land-cover classification using satellite data», *Science*, 227, pp. 369-375.

Tucker, C. J.; Newcomb, W. W. y Dregne, H. E. (1994): «AVHRR data sets for determination of desert spatial extent», *International Journal of Remote Sensing*, 15, pp. 3547-3565.

Tucker, C. J.; Yung, I. Y.; Keeling, C. D. y Gammon, R. H. (1986): «Relationship between atmospheric CO_2 variations and a satellite-derived vegetation index», *Nature*, 319, pp. 195-199.

Turner, M. G. (1989): «Landscape ecology: the effect of pattern on process», *Annual Review of Ecology and Systematics*, 20, pp. 171-197.

Turner, M. G.; Hargrove, W. W.; Gardner, R. H. y Romme, W. H. (1994): «Effects of fire on landscape heterogeneity in Yellowstone National Park, Wyoming», *Journal of Vegetation Science*, 5, pp. 731-742.

Unninayar, S. (1988): «The global system, observing and monitoring change. Data problems, data management and databases», en H. Mounsey (ed.) *Building Databases for Global Science*, Londres, Taylor and Francis, pp. 357-377.

Ustin, S. L. y Trabucco, A. (2000): «Using hyperspectral data to assess forest structure», *Journal of Forestry*, 98, pp. 47-49.

Ustin, S. L.; Roberts, D. S.; Pinzón, J.; Jacquemoud, S.; Gardner, M.; Scheer, B.; Castañeda, C. M. y Palacios-Orueta, A. (1998): «Estimating canopy water content of chaparral shrubs using optical methods», *Remote Sensing of Environment*, 65, pp. 280-291.

Valerio, A. y Ledesma, L. L. (1981): «Natural resources inventories by computer-satellite mapping techniques in Chaco state, Argentine Republic, South America», *15th Intern. Symp. Rem. Sens. of Environment*, Ann Arbor, pp. 1327-1338.

Valor, E. y Caselles, V. (1996): «Mapping Land Surface Emissivity from NDVI: Application to European, African, and South American Areas», *Remote Sensing of Environment*, 57, pp. 167-184.

Van Genderen, J. L. (1978): «Guidelines for using LANDSAT data for rural land use surveys in developing countries», *ITC Journal*, 1, pp. 30-49.

Van Wagner, C. E. (1974): *Structure of the Canadian Forest Fire Weather Index*, Ottawa, Canadian Department of Environment, Canadian Forestry Service, p. 1333.

Vargas, F. (2000): «Seguimiento de procesos de deforestación en la reserva de Ticoporo (Llanos occidentales de Venezela) mediante análisis multitemporal de imágenes de satélite», doctorado, Departamento de Geografía, Universidad de Alcalá.

Vargas, F. F. y Chuvieco, E. (1991): «Dinámica de la deforestación en regiones tropicales a partir del análisis multitemporal de imágenes SPOT», *Teledetección y Medio Ambiente*, Sevilla, Junta de Andalucía, pp. 70-76.

Vaughan, P. (2001): *Estimación de contenido de humedad de la vegetación mediante radiometría de campo*, Trabajo de investigación, Departamento de Geografía, Universidad de Alcalá.

Vega-García, C.; Lee B. y Wooddard, T. (1996): «Applying neural network technology to human-caused wildfire occurence prediction», *AI Applications*, 10, pp. 9-18.

Verbyla, D. (1995): *Satellite Remote Sensing of Natural Resources*, Boca Raton, Lewis Publishers.

Verdin, J. P. (1985): «Monitoring water quality conditions in a large Western reservoir with Landsat imagery», *Photogrammetric Engineering and Remote Sensing*, 51, pp. 343-353.

Verhoef, W. (1984): «Light scattering by leaf layers with application to canopy reflectance modeling: the SAIL model», *Remote Sensing of Environment*, 16, pp. 125-141.

Verhoef, W. y Peteri, P. W. (1984): «Digital mosaic of the Netherlands from Landsat MSS data in natural colour», *International Journal of Remote Sensing*, 5, pp. 749-751.

Vermote, E.; Tanré, D.; Deuzé, J. L.; Herman, M. y Morcrette, J. J. (1997): *Second Simulation of the Satellite Signal in the Solar Spectrum (6S)*, Greenbelt, MD, NASA Goddard Space Flight Center Code 923.

Verstraete, M. M. (1994): «Retrieving canopy properties from remote sensing measurements», en J. Hill y J. Megier (eds.), *Imagining Spectrometry, a tool for Environmental Observations*, Brussels, European Community ECSC, EEC, pp. 109-123.

Verstraete, M. M. y Pinty, B. (1996): «Designing optimal spectral indexes for remote sensing applications», *IEEE Transactions on Geoscience and Remote Sensing*, 34, pp. 1254-1265.

Vidal, A.; Pinglo, F.; Durand, H.; Devaux-Ros, C. y Maillet, A. (1994): «Evaluation of a temporal fire risk index in Mediterranean forest from NOAA thermal IR», *Remote Sensing of Environment*, 49, pp. 296-303.

Viedma, O.; Meliá, J. y Chica-Olmo, M. (1999): «Análisis espacial de los efectos del fuego sobre matorrales mediterráneos mediante semivariogramas aplicados a imágenes Landsat 5 TM», *Teledetección. Avances y Aplicaciones*, Albacete, España, Asociación Española de Teledetección, pp. 239-243.

Viovy, N.; Arino, O. y Belward, A. S. (1992): «The best index slope extraction (BISE): a method for reducing noise in NDVI time-series», *International Journal of Remote Sensing*, 13, pp. 1585-1590.

Vogelman, J. E. (1990): «Comparison between two vegetation indices for measuring different types of forest damage in the North-Eastern United States», *International Journal of Remote Sensing*, 12, pp. 2281-2297.

Wald, L. (1999): «Some Terms of Reference in Data Fusion», *IEEE Transactions on Geoscience and Remote Sensing*, 37, pp. 1190-1193.

Walsh, S. J., Butler, D. R. y Malanson, G. P. (1998): «An overview of scale, pattern, process relationships in geomorphology: a remote sensing and GIS perspective», *Geomorphology*, 21, pp. 183-205.

Wang, F. (1990): «Improving remote sensing image analysis through fuzzy information representation», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 1163-1169.

— (1993): «A knowledge-based vision system for detecting land changes at urban fringes», *IEEE Transactions on Geoscience and Remote Sensing*, 31, pp. 136-145.

Wang, L. y He, D. C. (1990): «A new statistical approach for texture analysis», *Photogrammetric Engineering and Remote Sensing*, 56, pp. 61-66.

Wang, Y. y Civco, D. L. (1994): «Evidential reasoning-based classification of multi-source spatial data for improved land cover mapping», *Canadian Journal of Remote Sensing*, 20, pp. 381-395.

Watson, C. E., Fishman, J. y Reichle, H. G. (1990): «The significance of biomass burning as a source of carbon monoxide and ozone in the southern tropics: a satellite analysis», *Journal of Geophysical Research*, 95, pp. 16443-16450.

Weber, J. A. y Ustin, S. L. (1991): «Diurnal water relations of walnut trees: implications for remote sensing», *IEEE Transactions on Geoscience and Remote Sensing*, 29, pp. 864-874.

Weiss, M.; Troufleau, D.; Baret, F.; Chauki, H.; Prévot, L.; Olioso, A.; Bruguier, N. y Brisson, N. (2001): «Coupling canopy functioning and radiative transfer models for remote sensing data assimilation», *Agricultural and Forest Meteorology*, 108, pp. 113-128.

Welch, R. y Usery, E. L. (1984): «Cartographic accuracy of Landsat-4 MSS and TM image data», *IEEE Transactions on Geoscience and Remote Sensing*, GE22, pp. 281-288.

Wesman, C. (1994): «Estimating canopy biochemistry through imaging spectrometry», en J. Hill y J. Megier (eds.), *Imagining Spectrometry, a tool for Environmental Observations*, Brussels, European Community ECSC, EEC, pp. 57-69.

Westman, C. A., Aber, J. D.; Peterson, D. L. y Melillo, J. M. (1988): «Remote sensing of canopy chemistry and nitrogen cycling in temperate forest ecosystems», *Nature*, 335, pp. 154-156.

Westman, W. E. y Price, C. V. (1988): «Spectral changes in conifers subjected to air pollution and water stress: experimental studies», *IEEE Transactions on Geoscience and Remote Sensing*, 26, pp. 11-20.

Wheeler, D. J. y Ridd, M. K. (1985): «A geographic information system for resource managers based on multi-level remote sensing data», *ASP 51st Annual Meeting. Technical Papers*, pp. 528-537.

Wilkie, D. S. y Finn, J. T. (1996): *Remote Sensing Imagery for Natural Resources Monitoring*, Nueva York, Columbia University Press.

Wilkinson, G. G. y Mégier, J. (1990): «Evidential reasoning in a pixel classification hierarchy. A potential method for integrating classifiers and expert system rules based on geographic context», *International Journal of Remote Sensing*, 11, pp. 1963-1968.

Wilkinson, M. J.; Lulla, K. P. y Glasser, M. (2000): «Biomass Burning and Smoke Palls with Observations from the Space Shuttle and Shuttle-Mir Missions», en K. P. Lulla y L. V. Dessinov (eds.), *Dynamic Earth Environments. Remote Sensing Observations from Shuttle - Mir Missions*, Nueva York, John Wiley and Sons, pp. 98-119.

Williamson, R. A. (2001): «Remote sensing policy and the development of commercial remote sensing», en J. C. Baker, K. M. O'Connell y R. A. Williamson (eds.), *Commercial Observation Satellites. At the leading edge of Global transparency*, Santa Monica, RAND - ASPRS, pp. 37-52.

Woldai, T. (1983): «Landsat and SIR-A interpretation of the Kalpin Chol and Chong Korum mountains of China», *ITC Journal*, 83, pp. 250-252.

Woodcock, C. E. y Strahler, A. H. (1987): «The factor of scale in remote sensing», *Remote Sensing of Environment*, 21, pp. 311-332.

Woodcock, C. E.; Strahler A. H. y Jupp D. L. (1988*a*): «The use of variograms in remote sensing: I. Scene models and simulated images», *Remote Sensing of Environment*, 25, pp. 323-348.

— (1988*b*): «The use of variograms in remote sensing: II. Real digital images», *Remote Sensing of Environment*, 25, pp. 349-379.

Wu, S. T. (1980): «An improvement in land cover classification achieved by merging microwave data with Landsat multispectral scanner data», *Photo-Interpretation*, 80, pp. 1-18.

Yocky, D. A. (1996): «Multiresolution wavelet decomposition image merger of Landsat Thematic Mapper and SPOT pancromatic data», *Photogrammetric Engineering and Remote Sensing*, 62, pp. 1067-1084.

Yool, S. R.; Eckhardt, D. W.; Estes, J. E. y Cosentino M. J. (1985): «Describing the brushfire hazard in southern California», *Annals of the Association of American Geographers*, 75, pp. 417-430.

Zarco-Tejada, P. J.; Miller, J. R.; Noland, T. L.; H. Mohammed, G. H. y Sampson, P. H. (1999): «Utilización de modelos de reflectancia como nexo entre muestras foliares y la cobertura forestal: aplicación a datos hiperespectrales», *Revista Española de Teledetección*, 12, pp. 21-32.

— (2001): «Scaling-Up and Model Inversion Methods with Narrowband Optical Indices for Chlorophyll Content Estimation in Closed Forest Canopies with Hyperspectral Data», *IEEE Transactions on Geoscience and Remote Sensing*, 39, pp. 1491-1507.

Zuylen, L. V. (1978): «The use of remote sensing for updating maps», *ITC Journal*, 78/2, pp. 333-346.

ANEXOS

Anexo I

ABREVIATURAS UTILIZADAS EN EL TEXTO

AATSR	*(Advanced Along Track Scanning Radiometer)*
ACP	(Análisis de Componentes Principales)
ADI	(Análisis Digital de Imágenes)
ALI	*(Advanced Land Imager)*
ALME	(Análisis Lineal de Mezclas Espectrales)
ALOS	*(Advanced Land Observing System)*
AMI	*(Active Microwave Instrument)*
ARVI	*(Atmospherically Resistant Vegetation Index)*
ASAR	*(Advanced Synthetic Aperture Radar)*
ASTER	*(Advanced Spaceborne Thermal Emisión and Reflection Radiometer)*
ATS	*(Applications Technology Satellite)*
ATSR	*(Along Track Scanning Radiometer)*
AVHRR	*(Advanced Very High Resolution Radiometer)*
AVIRIS	*(Airborne Visible/Infrared Imaging Spectrometer)*
BIL	*(Band Interleaved by Line)*
BIP	*(Band Interleaved by Pixel)*
BRDF	*(Bi-directional Reflectance Distribution Factor)*
BSQ	*(Band Sequential)*
CASI	*(Compact Airborne Spectrographic Imager)*
CCD	*(Charge Couple Devices)*
CERES	*(Clouds and the Earth's Radiant Energy System)*
CF	(Coeficientes de Filtraje).
CH	(Contenido de Humedad)
CLUT	*(Color Look Up Table)*
CNES	*(Centre National d'Études Spatiales*, Francia)
CRT	*(Cathode Ray Tube)*
CZCS	*(Coastal Zone Color Scanner)*
DAAC	*(Distributed Active Archive Center Alliance)*
DAIS	*(Digital Airborne Imaging Spectrometer)*
DLR	*(Deutschen Zentrum für Luft-un Raumfahrt*, Alemania)
DMSP	*(Defense Meteorological Satellite Program)*
EIFOV	*(Effective Instantaneous Field of View)*
EL	(Error longitudinal)
EO-1	*(Earth Observing-1)*

EOS *(Earth Observing System)*
EOSDIS *(Earth Observation System Data and Information System)*
ERBE *(Earth Radiation Budget Experiment)*
ERE *(Effective Resolution Element)*
EREP *(Earth Resources Experiment Package)*
ERS *(European Remote Sensing Satellite)*
ESA *(European Space Agency)*
ESC *(Electronic Sill Camera)*
ET (Evapotranspiración)
ETC *(Earth Terrain Camera)*
ETM *(Enhanced Thematic Mapper)*
EWT *(Equivalent Water Thickness)*
FBA *(Foreground/Background Analysis)*
FTP *(File Transfer Protocol)*
GAC *(Global Area Coverage)*
GARP *(Global Atmospheric Research Programme)*
Gb (Gigabyte, 10^9 bytes)
GCP *(GCPWorks)*
GEMI *(Global Environment Monitoring Index)*
GHz (Gigaherzios, 10^9 Hz)
GIF *(Graphics Interchange Format)*
GMT *(Greenwich Meridian Time)*
GOES *(Geostationary Operational Environmental Satellite)*
GOME *(Global Ozone Monitoring Experiment)*
GPS *(Global Positioning System)*
GVI *(Global Vegetation Index)*
HCMR *(Heat Capacity Mapping Radiometer)*
HIRIS *(High Resolution Imaging Spectrometer)*
HIRS/3 *(High Resolution Infrared Radiation Sounder)*
HRPT *(High Resolution Picture Transmission)*
HRV *(Haute Resolution Visible)*
Hz (Hertz)
IAE (índice de acuerdo espectral)
IFOV *(Instantaneous Field Of View)*
IGBP *(International Geosphere Biosphere Program)*
IHS *(Intensity, Hue, Saturation)*
INPE (Instituto Nacional de Pesquisas Espaciais, Brasil)
IRC (Infrarrojo cercano, situado entre 0,70 y 1,3 μ)
IRS *(Indian Remote Sensing Satellite)*
IRT (Infrarrojo térmico, situado entre 8 y 14 μm)
IV (Índices de vegetación)
IW *(Image Works)*
JPEG *(Joint Photographic Expert's Group)*
JPL *(Jet Propulsion Laboratory)*
Kb (Kilobyte, 10^3 bytes)
LAC *(Local Area Coverage)*
LAD *(Leaf Angle Distribution)*
LAI *(Leaf Area Index)*
LFC *(Large Format Camera)*
LISS *(Linear Imaging Self Scanning)*

Mb (Megabyte, 10^6 bytes)
MDE (Modelo Digital de Elevación)
MERIS *(Medium Resolution Imaging Spectrometer)*
MISR *(Multi-Angle Imaging Spectroradiometer)*
MNF *(Minimum Noise Fraction)*
MODIS *(Moderate-Resolution Imaging Spectroradiometer)*
MOPITT *(Measurements of Pollution In The Troposphere)*
MOS *(Marine Observation Satellite)*
MSG *(Meteosat Second Generation)*
MSS *(Multispectral Scanner)*
MSU *(Microwave Sounding Unit)*
MUC (Mínima Unidad Cartografiable).
NASA *(National Aeronautics and Space Administration)*
NASDA *(National Space Development Agency*, Japón)
ND (Nivel Digital, de cada píxel)
NDII *(Normalized Difference Infrared Index)*
NDVI *(Normalized Difference Vegetation Index)*
NGDC *(National Geophysical Data Center*, USA)
NOAA *(National Oceanic and Atmospheric Administration Satellite)*
NRSA *(National Remote Sensing Agency*, India)
NV (Niveles Visuales)
OLS *(Operational Linescan System)*
OPS *(Optical Sensor)*
PDUS *(Primary Data User Stations)*
PNG *(Portable Network Graphics)*
POAM *(Polar Ozone and Aerosol Measurement)*
POLDER *(Polarization and Directionality of the Earth's Reflectance)*
PPI *(Pixel Purity Index)*
PPU *(Patch per Unit)*
RBV *(Return Beam Vidicon)*
RMSE *(Root Mean Squared Error)*
RNA (Redes neuronales artificiales)
RVA (Rojo, Verde, Azul)
SAIL *(Scattered by Arbitraily Inclined Leaves)*
SAM *(Spectral Angle Mapper)*
SAR *(Synthetic Aperture Radar)*
SAVI *(Soil Adjusted Vegetation Index)*
SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer)*
SELPER (Sociedad de Expertos Latinoamericanos en Percepción Remota)
SIG (Sistemas de Información Geográfica)
SIR *(Shuttle Imaging Radar)*
SLA *(Specific Leaf Area)*
SLAR *(Side Looking Airborne Radar)*
SPOT *(Satellite Pour l'Observation de la Terre)*
SRTM *(Shuttle Radar Topography Mission)*
SBUV/2 *(Solar Backscatter UltraViolet Spectral Radiometer)*
SSM/I *(Special Sensor Microwave Imager)*
SSMR *(Scanning Multichannel Microwave Radiometer)*
SSU *(Stratospheric Sounding Unit)*
SWIR *(Short Wave Infrared*, comprendido entre 1,3 y 2,5 μm)

TA	(Temperatura del Aire)
TM	(*Thematic Mapper*)
TOVS	(*Tiros Operational Vertical Sounder*)
TRMM	(*Tropical Rainfall Measuring Misión*)
TS	(Temperatura de Superficie)
TTC	(Transformación *Tasseled Cap*)
VCL	(Vegetation *Canopy Lidar*)
VIS	(Visible, con un rango entre 0,4 y 0,7 μm)
XP	(*Xpace*)

ANEXO 2

GLOSARIO*

Abertura: Se habla de apertura de un sistema óptico por la relación entre la luz que deja pasar un diafragma y la que obstruye. *Aperture*.

Absorción atmosférica: Indica la eliminación que realiza la atmósfera de distintos tipos de energía, en razón de sus propios componentes, y principalmente del ozono, oxígeno atómico y vapor de agua. *Absorption*.

Activo, Sistema: Se habla de sensores activos, cuando son capaces de emitir sus propias ondas electro-magnéticas, y grabar posteriormente el haz reflejado por el objeto bajo estudio. *Active systems*.

Albedo: Ver reflectividad.

Aleteo: Es la consecuencia de la rotación de una plataforma sobre su eje longitudinal. *Roll*.

Anotaciones: Diversos elementos gráficos que son incorporados al tratamiento de las imágenes para mejorar su legibilidad.

Banda espectral: Se refiere este término a una selección de longitudes de onda con comportamientos electro-magnéticos similares. *Spectral band*.

Barrido multiespectral, Equipos de: Se trata de equipos sensores que permiten explorar secuencialmente la superficie de la Tierra, dividiendo la radiación captada en diversas bandas espectrales. *Multispectral scanner*.

Bit: Refiere a un dígito del sistema binario.

Byte: Un grupo de ocho bits de datos numéricos.

Cabeceo: Ocurre cuando una nave espacial se inclina a lo largo de su eje de vuelo. *Pitch*.

Calibración: Proceso de comparar ciertas medidas específicas con otro instrumento estándar. *Calibration*.

Cámara multibanda: Cámara que expone diferentes áreas a un film, o a más de un film, a través de una lente. Incluye diferentes objetivos, cada uno de los cuales presenta diversos filtros o tipos de película, de tal forma que puede obtenerse la misma porción del terreno en diferentes bandas espectrales. *Multiband camera*.

Cámara de gran formato: Se trata de un cámara que permite obtener negativos sobredi-

* Los términos se han extraído de distintos manuales de teledetección y diccionarios técnicos. Incluyen algunas modificaciones de los referenciados en la primera edición, considerando los términos que aportamos al *Diccionario de Cartografía* (editado por I. Otero en 1995, Madrid, Ediciones de Ciencias Sociales). Para una relación más detallada puede consultarse esta obra, así como el diccionario multilingüe de la SELPER, publicado en 1989. Un reciente glosario, con amplia explicación de cada término, ha sido publicado por Rees (1999).

mensionados, 23 × 46 cm, en lugar de los estándar, 23 × 23 cm. Se ha utilizado en diversas misiones del *Space Shuttle*. *Large Format Camera, LFC*.

Campo instantáneo de visión: Este término expresa el ángulo exacto de visión que es detectado en cada pauta de observación en un sistema de exploración electrónica. Normalmente se mide en grados o micro-radianes y se relaciona con la superficie real abarcada por el detector. *Instantaneous Field Of View, IFOV*.

Catódicos, Tubos de rayos: Un tubo en el vacío capaz de producir imágenes en Blanco y Negro o Color, mediante el choque de electrones sobe una superficie sensibilizada. *Cathode Ray Tube, CRT*.

Cintas compatibles con ordenador: Cintas magnéticas que contienen datos digitales. Aunque todavía constituyen el soporte más habitual de las imágenes de satélite, están siendo sustituidas paulatinamente por cartuchos o discos compactos. *Computer Compatible Tape, CCT*.

Clasificación digital: Proceso por el que se asigna un pixel de una imagen multi-espectral a una de las categorías de la leyenda, generalmente sobre la base de similitudes entre los valores numéricos que las definen. *Pattern recognition, digital classification*.

Clúster: Se habla de clúster o conglomerado cuando los píxeles o elementos de una imagen tienden a formar grupos con similares condiciones espectrales. El agrupamiento automático no supervisado pretende encontrar estos grupos espectrales idóneos como reflejo de los naturalmente existentes en la imagen.

Componentes principales: Es una técnica de tratamiento estadístico que permite condensar una serie de variables en un menor número sobre la base de sus correlaciones mutuas. *Principal components*.

Conducción: La transferencia de energía electromagnética a través de un material por interacción molecular. *Conduction*.

Contraste: Diferencia de valor o tono entre las áreas más claras y más oscuras de una imagen. *Contrast*.

Correcciones: Indican las operaciones digitales tendentes a eliminar errores en la adquisición de las imágenes, ya sean radiométricos o geométricos.

Cuerpo negro: Se trata de un emisor ideal, que radia el máximo de energía por unidad de superficie en cada longitud de onda y para un temperatura dada. Un cuerpo negro también absorbe toda la energía que sobe él incide. *Blackbody*.

Datos auxiliares: Medidas y observaciones acerca de los objetos, áreas o fenómenos que serán captados por algún medio de teledetección. Pueden ser mapas de ocupación del suelo, litología, análisis químicos, topografía, etc. *Data reference*.

Densidad, Intervalos de: Indica el proceso de convertir el tono continuo de una imagen en un pequeño número de tonos de gris o color, cada uno de los cuales corresponde a un intervalo digital determinado por el usuario. *Density slicing*.

Detección de cambios: Cualquier técnica que permita señalar sobre dos o más imágenes multitemporales aquellas zonas que han experimentado transformaciones. *Change detection*.

Digitización: El concepto refiere a cualquier conversión de un documento analógico en formato numérico. *Digitizing*.

Distorsión panorámica: Se produce en los sistemas de barrido por un efecto de diferenciación de escala, en la línea perpendicular a la dirección de vuelo.

Doppler, Efecto: La variación en la frecuencia de una señal, debido al movimiento del transmisor. *Doppler shift*.

Electromagnética, Energía: Energía propagada a través del espacio o de otro medio material en un modelo armónico ondulatorio con un componente magnético y otro eléctrico. *Electro-magnetic energy*.

Emisividad: Proporción entre la energía emitida por un determinado objeto y la que emitiría un cuerpo negro a la misma temperatura. *Emissivity*.

Escáner: Barredor óptico electrónico, que permite convertir un nivel de gris o color en un código numérico. *Scanner*.

Espectro electromagnético: Se trata de la agrupación de la radiación electromagnética en distintas bandas, definidas por la longitud de onda o la frecuencia, que presentan un comportamiento radiométrico similar. *Electro-magnetic spectrum*.

Estéreo-radian: Unidad de medida del ángulo sólido. *Stereo-radian*.

Filtros atmosféricos: Cualquier material que ya por absorción o por reflexión modifica selectivamente la radiación transmitida a través de la atmósfera. Los más destacados son el oxígeno, ozono, dióxido de carbono, monóxido de carbono y vapor de agua.

Filtros digitales: Se trata de matrices de coeficientes numéricos que permiten atenuar o acentuar —según su finalidad y estructura— las gradaciones radiométricas presentes en una imagen. *Digital filters*.

Frecuencia: Número de ciclos por segundo que pasan por un punto fijo. *Frequency*.

Gausiana, Distribución: Término estadístico que refiere a la disposición de las frecuencias observadas en una variable como ajustadas a la curva normal. *Gaussian distribution*.

Histograma: Una representación gráfica de las frecuencias observadas en una determinada imagen. *Histogram*.

Imagen: Cualquier forma de representación pictórica de los datos no obtenida por medios fotográficos. *Image*.

Inercia térmica: Es la medida de la respuesta de un material a los cambios de temperatura. *Thermal inertia*.

Infrarrojo: Porción del espectro comprendida entre 0,7 y 100 micras, que tiene gran importancia para estudios de teledetección. Normalmente suele dividirse en infrarrojo cercano, medio y lejano. Este último también se conoce como infrarrojo térmico. *Infrared*.

Infrarrojo color: Se trata de una composición coloreada en la cual se aplican a las bandas espectrales verde, roja e infrarrojo próximo, los colores naturales azul, verde y rojo, respectivamente. Resulta muy útil para detectar cambios en las condiciones de las superficies vegetales. *Color infrared*.

IRS: *Indian Resources Satellite*, satélite indio de recursos naturales.

JERS: *Japanese Earth Resources Satellite*, satélite japonés de recursos naturales.

Lambertiana, Superficie: Indica un perfecto difusor, que refleja la energía incidente, por igual, en todas las direcciones. *Lambertian*.

Landsat: Serie de satélites construida por NASA dedicados específicamente a la detección de recursos naturales.

Lídar: Se trata de un sensor activo que trabaja con luz polarizada o láser.

Longitud de onda: Es la medida de la distancia que separa dos valores culminantes entre sucesivas ondas. *Wavelength*.

Máxima verosimilitud: Es un criterio estadístico de clasificación digital de imágenes, por el cual se asigna cada pixel de la imagen a la categoría para la cual posee mayor probabilidad de pertenencia. *Maximum likelihood*.

Microdensitómetro: Es un instrumento capaz de traducir un escala de grises a formato digital, mediante la medida de la densidad del film. *Micro-densitometer*.

Micrómetro: Unidad de longitud empleada para medir longitudes de onda de alta frecuencia. Equivale a la millonésima parte de un metro. *Micrometer*.

Microondas: Porción del espectro electromagnético comprendida entre 1 mm y 1 m. *Microwave*.

Mie, Dispersión: Tipo de difusión atmosférica provocada por partículas con similares dimensiones a la longitud de onda de la radiación. *Mie scattering*.

MOS: *Marine Observation Satellite*, Satélite de recursos naturales diseñado por la agencia espacial japonesa (NASDA), con fines de investigación oceanográfica.

Mosaicos: Se trata de un ensamblaje de distintas imágenes aéreas o espaciales que cubren parte, al menos, del mismo territorio.
Nadir: Indica observación vertical de un sensor, hacia abajo, esto es hacia el centro de la Tierra. *Nadir.*
Nivel digital: Valor entero que traduce numéricamente la intensidad radiométrica recibida por un sensor óptico-electrónico. *Digital number, pixel value.*
Orientación angular: Menciona la orientación de un sistema de teledetección con respecto a una referencia geográfica. *Attitude.*
Orto-fotografía: Fotografía corregida de las distorsiones del relieve. *Ortophotography.*
Pasivo, Sistema: Un sistema sensor que detecta la radiación emitida desde el objetivo o reflejada por él. *Pasive systems.*
Píxel: Derivado del inglés «*picture element*». Es el elemento pictórico más pequeño de las imágenes que es susceptible de ser procesado.
Puntos de control: Se trata de elementos geográficos que pueden ser localizados precisamente en una imagen y en un mapa para ser empleados en la corrección cartográfica de dicha imagen. *Ground Control Point, GCP.*
Radar: Sistema activo de micro-ondas que emite un haz energético sobre la superficie terrestre para luego recoger su reflexión sobre ella. Existen dos tipos de radar: el lateral, y el de apertura sintética. *Radar.*
Radiación: El proceso en el que la energía electromagnética es propagada a través del espacio libre.
Radiancia: Total de energía radiada por unidad de área y por ángulo sólido de medida. *Radiance.*
Radiómetro de microondas: Es un instrumento para medir la energía radiada por las superficies con una longitud de onda de milímetros o centímetros. *Microwave radiometer.*
Rayleigh, Dispersión: Se produce por partículas atmosféricas mucho más pequeñas en tamaño que la longitud de onda de la radiación. *Rayleigh scattering.*
Realce de imágenes: Procesos digitales que tienen como fin mejorar la calidad visual de la imagen, mediante el aumento del contraste interno o la creación de nuevas bandas que ilustren mejor sobre sus características originales. *Enhancement.*
Realce de bordes: Proceso particular de realce que tiene como objetivo enfatizar las áreas de transición en una imagen. *Edge enhancement.*
Reflectividad: Porcentaje de radiación incidente que es reflejada por una superficie bidimensional. *Reflectance.*
Resolución: La resolución es la medida de la habilidad de un sistema sensor para discriminar información dentro de la imagen. Refiere al tamaño de la mínima unidad de información en el terreno (espacial), al número de bandas disponibles (espectral), a los niveles de codificación (radiométrica) o a la frecuencia de cobertura (temporal). *Resolution.*
Ruido de la escena: Concepto que refiere a la variabilidad espectral hallada en el interior de las distintas clases temáticas. *Scene noise.*
Ruidos atmosféricos: Refiere este término a las interferencias imprevistas y más o menos aleatorias que introducen una degradación en los datos originales. *Atmospheric noise.*
Sensor: Cualquier instrumento que detecta energía electromagnética, la convierte en una señal y la presenta en forma susceptible de ser aprovechada para su estudio.
Signatura espectral: Forma peculiar de reflejar o emitir energía de un determinado objeto o cubierta. Está afectadas por las características físicas o químicas del objeto que interaccionan con la energía electro-magnética, y varía según las longitudes de onda. *Spectral signature.*
Sistema de información geográfica: Conjunto de programas que permiten almacenar, recuperar, modificar y combinar cualquier tipo de variables georeferenciadas. *Geographic information systems.*

Suavizado de imágenes: Operación digital que tiene por objeto obtener una mayor generalización en los resultados.
Teledetección: Es la técnica que permite obtener información sobre un objeto, área o fenómeno a través del análisis de los datos adquiridos por un instrumento que no está en contacto con el objeto, área o fenómeno bajo investigación. *Remote sensing.*
Termografía: La termografía es la rama de la teledetección que se ocupa de la medición de la temperatura radiada por los fenómenos de la superficie de la Tierra desde una cierta distancia. *Thermography.*
Teselar, Estructura: Sistema de almacenamiento de datos en un SIG que parte de dividir el terreno en una serie de celdillas regulares, sobre las que se codifican las distintas variables que integran el sistema. *GRID-Based GIS.*
Thematic mapper: Se trata de un equipo de barrido multiespectral bastante sofisticado, que se incorpora a los satélites de recursos naturales Landsat-4 y 5.
Vectorial, Estructura: Forma de almacenamiento de datos en un SIG, en el cual las distintas unidades temáticas se definen por las coordenadas de sus bordes. Una descripción topológica asociada a esa información gráfica permite reconstruir, posteriormente, las variables temáticas asociadas a esos polígonos. *VECTOR-Based GIS.*
Ventanas atmosféricas: Aquellas porciones del espectro en las cuales la atmósfera ofrece poca atenuación a la radiación electro-magnética. *Atmospheric window.*
Verdad terreno: Refiere a todas las medidas de magnitudes físicas y muestreos llevados a cabo sobre el área materia de operación. *Ground truth.*
Vidicon, Sistema: Es un tubo electrónico sensor de imágenes en el cual la imagen es recibida y alimentada sobre la superficie de un fotoconductor que sostiene el barrido electrónico. *Return Beam Vidicon.*
Visualización de datos: Cualquier representación visual de imágenes digitales. Puede realizarse sobre un monitor de rayos catódicos, un plotter electrostático, plotter de láser o impresora de líneas. *Display.*

ANEXO 3

ÍNDICE TEMÁTICO

A

B

C

D

E

F

G

H

I

J

K

L

M

N

O

P

Q

R

S

T

ANEXO 4

FUENTES ADICIONALES DE INFORMACIÓN*

1. Centros internacionales dedicados a teledetección espacial

— *Australian Centre for Remote Sensing*, P.O. Box 28, Belconnen, A.C.T. 2616, Australia.
— *Canada Centre for Remote Sensing*, 588 Booth Street, CDN Ottawa, Ontario K1A 0Y7, Canada.
— *DLR*, Forschungszentrum, Post Wessling/0BB, D-8031 Oberpfaffenhofen, Deutschland.
— USGS - *EROS Data Center*, National Mapping Division, Sioux Falls, SD 57198, USA.
— *European Space Agency*, 8-10 rue Mario Nikis, F-75738 Paris Cedex 15, France.
— *Jet Propulsion Laboratory*, California Institute of Technology, 4800 Oak Grove Drive, Pasadena, CA91103, USA.
— Joint Research Center, JRC-Ispra Site, 21020 Ispra, Varese, Italia.
— *NASA Goddard Space Flight Center*, Greenbelt, MD 20771, USA.
— *National Remote Sensing Agency*, Balanagar, Hyderabad-500 037, India.
— *National Remote Sensing Center*, Space Department, Royal Aircraft Establishment, Farnborough, Hampshire GU14 6TO, United Kingdom.
— *National Space Development Agency of Japan (NASDA)*, 1401 Ohashi, Hotoyama-Machi, Hikigum, Saitama 350-03, Japan.
— *RESTEC, Remote Sensing technology Center of Japan*, Roppongi Fiorst Bldg, 2F, 1-9-9106 Tokyo, Japan.

2. Centros iberoamericanos dedicados a teledetección espacial
(ver también centros docentes)

— *Agencia de Medio Ambiente, Junta de Andalucía*, Servicio de Evaluación de Recursos Naturales, Pabellón de Nueva Zelanda, Avda. Acacias, s/n, Isla de la Cartuja, 41092 Sevilla, España.
— *Centro de Levantamientos Integrados de Recursos Naturales por Sensores Remotos* (CLIRSEN), Apartado 8216, Quito, Ecuador.
— *Centro de Procesamiento Digital de Imágenes* (CPDI) - *Instituto de Ingeniería*, Apartado 40200, Caracas 1040-A, Venezuela.

* En el CD-ROM adjunto se amplía notablemente esta información, especialmente en lo que se refiere a organismos distribuidores de datos, sensores y recursos didácticos.

- *CREAF (Universitat Autónoma de Barcelona)*, 08193 Bellaterra. Coordinador Europeo del programa *CORINE Land Cover*.
- *Inisel Espacio*, Mar Egeo s/n, Polígono Industrial I, 28830 San Fernando de Henares, España.
- *Institut Cartogràfic de Catalunya*, Parc de Montjuïc, 08038 Barcelona, España.
- *Instituto Geográfico Nacional*, Sección de Teledetección, General Ibáñez de Ibero, s/n. 28003 Madrid, España.
- *Instituto Geográfico Agustín Codazzi*, Carrera 30 No. 48-51, Bogotá D.E., Colombia.
- *Instituto Nacional de Pesquisas Espaciais* (INPE), Av. Dos Astronautas 1758, São José dos Campos - SP, estado de São Paulo, Brasil.
- *Instituto Nacional de Estadística, Geografía e Informática (INEGI)*, Av. Héroe de Nacozari Sur 2301, Aguascalientes, 20290 México.

3. Sociedades profesionales

- *American Society of Photogrammetry and Remote Sensing*, 5420 Grosvenor Lane, Suite 210, Bethesda 20814-2160, USA.
- *Asian Association on Remote Sensing*, Institute of Industrial Science, University of Tokyo, 7-32 Roppongi, Minatoku, Tokyo, Japan.
- *Asociación Española de Teledetección*, Pinar 25, 28008 Madrid.
- *Canadian Remote Sensing Society*, 222 Somerset Street West, Suite No. 601, Ottawa, Ontario K2P 0J1, Canada.
- *European Association of Remote Sensing Laboratories*, EARSeL Secretariat, 2 Avenue Rapp, F-75340 Paris Cedex 07, France.
- *Remote Sensing Society*, Department of Geography, University of Nottingham, Nottingham NG7 2RD, United Kingdom.
- *Sociedad de Especialistas Latinoamericanos en Percepción Remota* (SELPER) (sede para 2000 a 2002): Universidad Nacional de Luján, Argentina.

4. Centros docentes

- *Carnegie Laboratory of Physics, University of Dundee*, Dundee DD1 4HN, Scotland, United Kingdom.
- *Center for Remote Sensing, Imperial College of Science and Technology, Department of Physics*, Prince Consort Road, London SW7 2AZ, United Kingdom.
- *Environmental Remote Sensing Center, University of Winsconsin-Madison*, 1225 West Dayton Street, Madison, WI 53706, USA.
- *Groupement pour le Dévelopment de la Télédétection Aérospatial* (GDTA), Centre Spatiale de Toulouse, 18 Avenue Edouard Belin, F-31055 Toulouse.
- *Instituto Nacional de Pesquisas Espaciais* (INPE), Av. Dos Astronautas 1758, São José dos Campos - SP, estado de São Paulo, Brasil.
- *International Institute for Aerospace Survey and Earth Sciences* (ITC), P.O. Box 6, NL-7500 AA, Enschede, Nederland.
- *Universidad Católica de Chile, Programa de Percepción Remota y SIG*, Campus San Joaquín, Santiago, Chile.
- *Universidad de Alcalá, Departamento de Geografía*. Calle Colegios, 2. 28801 Alcalá de Henares, España.
- *Universidad de Valencia, Departamento de Termodinámica. Facultad de Ciencias Físicas*, Doctor Moliner 50, 46100 Burjassot, Valencia, España.

- *Universidad Nacional de Luján, Programa Proditel*, Campus Universitario, Luján, Argentina.

5. Revistas especializadas en teledetección

- *Canadian Journal of Remote Sensing*, Canadian Aeronautics and Space Institute (CASI) 130 Slater Street, Suite 818, Ottawa, Ontario K1P 6E2, Canada. (http://www.casi.ca).
- *Earth Observation Magazine*, EOM, Inc., 13741 E. Rice Place, Suite 200, Aurora, CO 80015 (USA). (http://www.eomonline.com).
- *Geocarto International*, Geocarto International Centre, GPO Box 4122, Hong Kong. (http://www.geocarto.com).
- *IEEE Transactions on Geoscience and Remote Sensing*, IEEE Geoscience and Remote Sensing Society, Institute of Electrical and Electronics Engineers Inc., 345 E. 47th Street, New York, NY, 10017 USA. (http://www.ieee.org/pub_preview/grs_toc.html).
- *International Journal of Geographical Information Science*, Taylor and Francis Ltd., Rankine Road, Basingstoke, Hampshire RG24 0PR, United Kingdom. (http://www.bmpub.com/JNLS/gis.htm).
- *International Journal of Remote Sensing*, Taylor and Francis Ltd., Rankine Road, Basingstoke, Hampshire RG24 0PR, United Kingdom. (http://www.bmpub.com/JNLS/RES.HTM).
- *ITC Journal*, International Institute for Aerospace Survey and Earth Sciences, P.O. Box 6, NL-7500 AA, Enschede, Nederland. (journal@itc.nl).
- *Mapping Sciences and Remote Sensing*, Bellwether Publishing, Ltd. 640 Guilford Road, Suite 200 Columbia, MD 21046-2612 (USA).
- *Photogrammetria*, Elsevier Scientific Publishing Company, Box 211, NL-1000 AE Amsterdam, Nederland.
- *Photogrammetric Engineering and Remote Sensing*, American Society for Photogrammetry and Remote Sensing, 5420 Grosvenor Lane, Suite 210, Bethesda 20814-2160, USA. (http://www.asprs.org/publications.html).
- *Photointerprétation*, Éditions Technip, 27 rue Ginoux, F-75737, Paris Cedex 15, France.
- *Remote Sensing of Environment*, Elsevier Science Publishing Company Inc., 52 Vanderbilt Avenue, New York, NY 10017, USA. (http://www.elsevier.com/inca/publications/store/5/0/5/7/3/3/index.htt).
- *Remote Sensing Reviews*, Harwood Academic Publishers, 50 W. 23rd Street, New York, NY 10010, USA.
- *Revista Española de Teledetección*, Pinar 25, 28006 Madrid. (http://telenet.uva.es/revistas/aet/aet.html).

6. Organismos dedicados a la distribución de imágenes

- *INTA - División Ciencias del Espacio* (representante español de la red europea EARTHNET). Carretera de Ajalvir, km. 4, 28850 Torrejón de Ardoz, España.
- *NOAA (National Oceanic and Atmospheric Administration)*, NESDIS, World Weather Building, Room 100, Washington, D.C. 20233, USA.
- *Radarsat International*, 3851 Shell Rd, Suite 200, CDN-Richmond, B.C. V6X 2W2, Canada.
- *SPOT-Image*, 5 rue des Satelites, Toulousse, B.P. 4359, F-31030, France.
- *U.S.Geological Survey, EROS Data Center*, Sioux Falls, SD 57198.

7. **Empresas dedicadas a la fabricación de equipos de tratamiento digital de imágenes**

— ENVI, Research Systems Inc., 2995 Wilderness Place, Boulder, CO 80301, USA.
— ERDAS, 430 Tenth Street, N.W., Suite N206, Atlanta, GA 30318.
— ER-Mapper, 87 Colin Street, West Perth, Western Australia 6005.
— ESRI, 380 New York St. Redlands CA92373, USA.
— Idrisi, Clark University, Clark Labs for Cartographic Technology and Geographic Analysis, 950 Main Street, Worcester MA 01610-1477, USA.
— Ilwis, International Institute for Aerospace Survey and Earth Sciences (ITC), P.O. Box 6, NL-7500 AA, Enschede, Nederland.
— Intergraph, One Madison Industrial Park, Mail Stop IW17 B6, Huntsville, Alabama 35894, USA.
— PCI, 50 Est Wilmot, Ontario, Canada.

ANEXO 5

SITUACIÓN Y CARACTERÍSTICAS DE LAS IMÁGENES UTILIZADAS EN LOS CAPÍTULOS 6 Y 7

1. *Denominación en el texto:* TORREL00
   Sensor: Landsat-ETM+
   Fecha de adquisición: 15-03-2000
   Hora: 10:48 GMT
   Acimut solar: 146,58°
   Elevación solar: 42,39°
   Calibración: Ver tabla 6.5

2. *Denominación en el texto:* MADRID00
   Sensor: Landsat-ETM+
   Fecha de adquisición: 15-03-2000
   Hora: 10:48 GMT
   Acimut solar: 146,58°
   Elevación solar: 42,39°
   Calibración: Ver tabla 6.5

3. *Denominación en el texto:* ALCALÁ99
   Sensor: Landsat-ETM+
   Fecha de adquisición: 20-08-1999
   Hora: 10:48 GMT
   Azimut solar: 138,12°
   Elevación solar: 55,82°
   Calibración: Ver tabla 6.5

4. *Denominación en el texto:* TORREL84
   Sensor: Landsat-TM
   Fecha de adquisición: 2-08-1984
   Hora: 10:24 GMT
   Acimut solar: 123,42°
   Elevación solar: 56,12°
   Calibración: Ver tabla 6.5

5. *Denominación en el texto:* MADRID92
   Sensor: Landsat-TM
   Fecha de adquisición: 13-08-1992
   Hora: 10:18 GMT
   Acimut solar: 129,62°
   Elevación solar: 50,47°
   Calibración: Ver tabla 6.5

6. *Denominación en el texto:* IBÉRICA01
   Sensor: NOAA-AVHRR
   Fecha de adquisición: 15-09-1999
   Hora: 15:25 GMT
   Acimut solar: Varios
   Elevación solar: Varios
   Calibración: Directa de la estación utilizando los coeficientes de la NOAA

7. *Denominación en el texto:* ALCALÁ87
   Sensor: KVR-1000
   Fecha de adquisición: 1-08-1987
   Hora: 10:37
   Acimut solar: No disponible
   Elevación solar: 63,6°
   Calibración: No disponible

8. *Denominación en el texto:* ARICA00
   Sensor: IRS 1C-P
   Fecha de adquisición: 18-03-2000
   Hora:
   Acimut solar: 59,9°
   Elevación solar: 57,3°
   Calibración: Sesgo: 5,68; Ganancia: 10,48